

UNIVERSIDADE DE LISBOA
FACULDADE DE CIÊNCIAS
DEPARTAMENTO DE ENGENHARIA GEOGRÁFICA, GEOFÍSICA E ENERGIA



Classificação de imagens multiespectrais para elaboração de cartografia de base topográfica

Mário Jorge Rosado Balão

Mestrado em Engenharia Geoespacial

Trabalho de Projeto orientado por:
Prof. Doutor João Catalão Fernandes

AGRADECIMENTOS

O presente trabalho projeto representa o culminar da formação académica na área das ciências geográficas, como tal torna-se oportuno agradecer o apoio de todos o que estiveram presentes durante esta caminhada.

Em primeiro agradeço à minha filha e esposa, a quem muitas vezes devido ao forte empenhamento académico tive de privar de algum tempo não dando muitas vezes a atenção devida, um muito obrigado pelo apoio.

Ao CIGeoE pelo acompanhamento dado na fase de investigação do projeto, em especial ao TCOR ART Rui Teodoro e MAJ ART António Franco, que deram o seu contributo desde a fase inicial de escolha do presente tema.

Um muito obrigado a todos os docentes do DEGGE sem exceção pela qualidade da formação ministrada, fruto do elevado conhecimento, profissionalismo e espírito de missão de todos os que dele fazem parte.

Um agradecimento especial ao Professor Doutor João Catalão Fernandes por toda a atenção dada na orientação do trabalho, refletida em todas as reuniões pelos seus pareceres fundamentais para a consecução do projeto.

Deixando ainda um agradecimento a todos os colegas, camaradas e amigos que direta ou indiretamente me acompanharam durante esta fase.

RESUMO

O presente trabalho tem como objetivo avaliar a qualidade da cartografia topográfica de escala 1:25000, obtida a partir de imagens multiespectrais de satélites de elevada resolução espacial no âmbito do catálogo de objetos e especificações técnicas da cartografia do CIGeoE para a folha 1:25000, série M888, carta de base da cartografia Nacional. Será efetuado um estudo comparativo utilizando dois tipos de dados imagem, imagens multiespectrais do satélite GeoEye I e ortoimagens obtidas através de voo fotogramétrico, ambas com 4 bandas RGB+NIR. O projeto está dividido em três fases: classificação de imagem, filtragem de imagem e edição e generalização cartográfica. A primeira fase diz respeito à classificação de imagem, tendo-se usado os algoritmos de classificação Máxima Verosimilhança, *Support Vector Machine* e Árvores de Decisão (AD). No caso das AD, para além das 4 bandas das imagens referidas foram inseridas 2 bandas adicionais através do cálculo de dois índices, NDVI e RRR. Após a classificação passamos à fase de filtragem onde são criadas máscaras binárias das classes a extrair e aplicados filtros espaciais e operadores morfológicos. Após a eliminação de grande parte do ruído passa-se à fase de generalização cartográfica de forma a regularizar a informação adquirida via classificação e equipará-la à adquirida via restituição fotogramétrica. Para efeitos de avaliação do processo de extração de informação cartográfica foi tomada como referência a informação adquirida por operadores fotogramétricos do CIGeoE aquando a elaboração da carta 1:25000 da área de estudo, definida pela zona urbana da região de Samora Correia e enquadrada pelas cartas nº 404 e 405 série M888 do CIGeoE. Todas as fases têm um processo de avaliação associado, sendo que apenas transitam para a fase seguinte os produtos com melhor resultado, na última fase avaliativa é efetuada uma adaptação ao STANAG 2215, com vista a avaliar se o melhor resultado obtido a nível de exatidão posicional é viável para produção de cartografia 1:25000 do CIGeoE. Foi concluído que embora os resultados obtidos sejam favoráveis à utilização de técnicas de deteção remota para elaboração de cartografia de base topográfica, deverá ser equacionado um controle de qualidade à informação adquirida assim como a disponibilização da informação a um operador fotogramétrico, de forma a verificar se esta se reveste numa mais valia para o restituidor, permitindo uma otimização do tempo de restituição da carta, o presente estudo deverá ainda ser alargado a todos os objetos constantes nas normas de aquisição.

PALAVRAS CHAVE: Árvores de Decisão, Cartografia de Base, Deteção Remota, Imagens Multiespectrais, Generalização, Máxima Verosimilhança, Support Vector Machine, NDVI, RRR.

ABSTRACT

This paper aims to evaluate the quality of topographic cartography obtained from high resolution multispectral images, within the scope of the object catalog and technical specifications of CIGeoE cartography for sheet 1: 25000, M888 series, base of the National cartography. A comparative study using two types of data, multispectral images of the satellite GeoEye-1 and orthoimages obtained by photogrammetric flight, both with 4 bands RGB + NIR, is done. The project is divided into three phases: image classification, image filtering, cartographic generalization and editing. First, we use the Maximum Likelihood classification, Support Vector machine and Decision Tree algorithms for the image classification. The classification algorithms have used the four image bands and two additional bands with the NDVI index and the Red Roof Remove index. The resulting image classification is filtered for noise removal and spatial filters and morphological operators are applied. The last phase is the cartographic generalization, aimed to regularize the classification information acquired and to match it with the information acquired by the photogrammetric operators. To assess the quality of the resulting cartographic information, the cartographic information processed by CIGeoE photogrammetric operators is taken as a reference. For that the urban area of Samora Correia and framed by CIGeoE charts N°404 and 405, series M888, scale 1:25000 was used. All phases have an associated evaluation process, and only the products with the best results are carried over to the next phase. In the last evaluation phase, an adaptation to the STANAG 2215 is carried out to assess whether the best result gets a good horizontal accuracy to make a CIGeoE 1: 25000 maps. It was concluded that although the results are favorable to the use of remote sensing techniques in topographic cartography, an additional editing effort to meet the standards of the CIGeoE cartographic production. The present study should also be extended to all objects contained in the acquisition rules of CIGeoE.

KEYWORDS: Decision Tree, Base Map Cartography, Multispectral Images, Generalization, Maximum Likelihood, Remote Sensing, Support Vector Machine, NDVI, RRR.

ÍNDICE

AGRADECIMENTOS	i
RESUMO	iii
ABSTRACT.....	v
ÍNDICE.....	vii
LISTA DE TABELAS	ix
LISTA DE FIGURAS.....	xi
ACRÓNIMOS.....	xiii
Capítulo 1.....	1
INTRODUÇÃO.....	1
1.1 - ENQUADRAMENTO	1
1.2 - DELIMITAÇÃO DO TEMA	1
1.3 - MOTIVAÇÃO E OBJETIVOS.....	2
1.4 - ESTRUTURA DO TRABALHO DE PROJETO.....	2
Capítulo 2.....	5
ESTADO DA ARTE.....	5
Capítulo 3.....	9
DADOS E MÉTODOS.....	9
3.1 - CARACTERIZAÇÃO DA ÁREA DE ESTUDO	9
3.2 - DADOS UTILIZADOS	10
3.2.1. Imagem Satélite.....	10
3.2.2. Ortoimagem.....	10
3.2.3. Dados Vetoriais	11
3.3 - MÉTODOS.....	12
3.3.1. Algoritmos de Classificação Supervisada	12
3.3.1.1. Máxima Verosimilhança	14
3.3.1.2. Support Vector Machine	15
3.3.2. Classificação por Árvores de Decisão	16
3.3.3. Filtragem e Morfologia Binária.....	18
3.3.4. Transformação e Tratamento de Informação Vetorial	19
3.3.4.1. Generalização da Classe Edificado Habitacional	20

3.3.4.2.	Generalização da Classe Asfalto	21
3.3.5.	Avaliação e Validação de Informação.....	22
3.3.5.1.	Avaliação Nível I.....	23
3.3.5.2.	Avaliação Nível II – Edificado Habitacional	24
3.3.5.3.	Avaliação Nível II – Asfalto	26
3.3.5.4.	Avaliação Global.....	27
Capítulo 4.....	29	
RESULTADOS E DISCUSSÃO	29	
4.1 - CLASSIFICAÇÃO DE IMAGEM	29	
4.1.1.	Classificação de Imagem de Satélite	29
4.1.2.	Classificação da Ortoimagem.....	31
4.5 - MORFOLOGIA BINÁRIA E FILTRAGEM	34	
4.2.1.	Máscara da Classe Edificado Habitacional	34
4.2.2.	Máscara da Classe Asfalto	36
4.2 - GENERALIZAÇÃO DA INFORMAÇÃO ADQUIRIDA	37	
4.3.1.	Generalização da Classe Edificado Habitacional	37
4.3.1.1.	Classe Edificado Habitacional Irregular.....	38
4.3.1.2.	Classe Edificado Habitacional Regular	40
4.3.2.	Generalização da Classe Asfalto	43
4.3.3.	Avaliação Final.....	46
Capítulo 5.....	49	
CONCLUSÕES E PERSPETIVAS FUTURAS	49	
5.1 - PRINCIPAIS CONCLUSÕES	49	
5.2 - POTENCIAIS UTILIZAÇÕES DO PROCESSO	51	
5.3 - PERSPETIVAS FUTURAS	51	
Referências Bibliográficas	53	
ANEXO A – ÁRVORE DE DECISÃO DA ORTOIMAGEM	55	
ANEXO B – AMOSTRA DE HISTOGRAMAS DA ORTOIMAGEM.....	57	

LISTA DE TABELAS

Tabela 3.1— Imagem de Satélite.	10
Tabela 3.2 – Parâmetros da imagem aérea adquirida pela câmara UltraCam – XPWa	11
Tabela 3.3 – Dados Vetoriais	11
Tabela 3.4 – Terminologia das Árvores	16
Tabela 3.5 – Matriz de Contingências.....	23
Tabela 3.6 – Avaliação do Coeficiente (k).....	24
Tabela 3.7 – Classificação em termos de Precisão Horizontal Absoluta	27
Tabela 4.1 – Precisão Global e Coeficiente k - Satélite	29
Tabela 4.3 – Precisão Global e Coeficiente k – Ortoimagem	31
Tabela 4.4 – Tabela de Contingências AD-Ortoimagem	32
Tabela 4.5 – Tabela de Contingências AD-Ortoimagem Validação	34
Tabela 4.6 – Avaliação Nível II - EH Irregular.....	40
Tabela 4.7 – Avaliação Nível II – EH Regular (m)	42
Tabela 4.8 – Avaliação Nível II - EH Regular Geometria (m)	43
Tabela 4.9 – Avaliação da Classe Asfalto	46
Tabela 4.10 – Avaliação CMAS	47

LISTA DE FIGURAS

Figura 3.1 – Enquadramento da Área de Estudo.....	9
Figura 3.2 – Metodologia Adotada	12
Figura 3.3 – Áreas de Treino.....	13
Figura 3.4 – Metodologia Classificação Supervisada	13
Figura 3.5 – Funcionamento do algoritmo MV	14
Figura 3.6 – Hiperplano ótimo SVM	15
Figura 3.7 – Árvore Binária	16
Figura 3.8 – Metodologia AD	18
Figura 3.9 – Elemento Estruturante	18
Figura 3.10 – Dilatação e Erosão da Imagem	19
Figura 3.11 – Tratamento de Informação Vetorial.....	19
Figura 3.12 – Exemplo do resultado da classificação para a classe Edificado Habitacional..	20
Figura 3.13 – Regularização de Edifícios	20
Figura 3.14 – Simplificação de Edifícios	21
Figura 3.15 – Criação da Rede Viária	22
Figura 3.16 – Processo de Avaliação.....	23
Figura 3.17 – Itens a avaliar, Nível II EH Regular/Irregular	25
Figura 3.18 – Processamento de informação, avaliação Nível II-EH Regular	26
Figura 3.19 – Processamento de Informação Avaliação Nível II-Asfalto	26
Figura 4.1 – Classificação SVM- Imagem Satélite	30
Figura 4.2 – Classificação AD-Ortoimagem.....	31
Figura 4.3 – Região de Validação do Algoritmo AD.....	33
Figura 4.4 – Imagem Binária da Classe EH SVM-Satélite	35

Figura 4.5 – Imagem Binária da Classe EH AD-Orto	35
Figura 4.6 – Imagem Binária da Classe EH MV-Orto.....	35
Figura 4.7 – Imagem Binária da Classe asfalto SVM-Satélite.....	36
Figura 4.8 – Imagem Binária da Classe asfalto AD-Ortoimagem	36
Figura 4.9 – Imagem Binária da Classe asfalto MV-Ortoimagem.....	37
Figura 4.10 – Modelo de Generalização Classe EH	38
Figura 4.11 – Generalização EH Irregular AD – Orto	39
Figura 4.12 – Generalização EH Irregular MV	39
Figura 4.13 – Generalização EH Irregular SVM – Satélite	39
Figura 4.14 – Amostra EH Irregular	40
Figura 4.15 – Generalização EH Regular AD – Orto	41
Figura 4.16 – Generalização EH Regular MV – Orto.....	41
Figura 4.17 – Generalização EH Regular SVM – Satélite.....	41
Figura 4.18 – Amostra EH Regular.....	42
Figura 4.19 – Modelo de Simplificação da Classe Asfalto	43
Figura 4.20 – Resultado de Passagem para Linha Central AD - Orto	44
Figura 4.21 – Resultado de Passagem para Linha Central MV – Orto	44
Figura 4.22 – Resultado de Passagem para Linha Central SVM – Satélite	44
Figura 4.23 – Resultado Final Classe Asfalto AD	45
Figura 4.24 – Resultado Final Classe Asfalto SVM	45

ACRÓNIMOS

AD	Árvore de Decisão
CIGeoE	Centro de Informação Geoespacial do Exército
CNN	Convolutional Neural Networks
DR	Deteção Remota
EH	Edificado Habitacional
k	Coeficiente kappa
MDS	Modelo Digital de Superfície
MDT	Modelo Digital do Terreno
MKL	Multiple Kernel Learning
MV	Máxima Verosimilhança
NDVI	Normalized Difference Vegetation Index
RMS	Erro Médio Quadrático
ROI	Region of Interest
RRR	Red Roof Remove
SPOT	Système Probatoire d' Observation de la Terre
SVM	Support Vector Machine
UE	União Europeia

CAPÍTULO 1

INTRODUÇÃO

1.1 - ENQUADRAMENTO

A produção cartográfica tem usado desde há algumas décadas imagens aéreas para efetuar a restituição e representação da superfície do terreno, recorrendo para ao efeito a processos fotogramétricos. Contudo, outras tecnologias paralelas têm vindo a ser desenvolvidas como é o caso da área aeroespacial, que tem tido um crescimento exponencial nas últimas décadas.

O estudo e conceção de novos satélites de observação da terra tem vindo a ser uma das principais aplicações desta área, onde a engenharia geoespacial contribui com o cálculo de órbitas e outros algoritmos para que possam ser extraídos vários produtos das imagens obtidas através dos sensores a bordo dos satélites, sendo a deteção remota a área destinada a esse fim.

No que respeita às várias aplicações, a deteção remota tem vindo a evoluir paralelamente ao desenvolvimento dos sensores, uma vez que a qualidade dos produtos obtidos por esta via está diretamente relacionada com o aumento da resolução espacial e radiométrica dos sensores, daí que a aplicação de algoritmos de classificação de imagem, deteção de alterações entre outros têm vindo a evoluir favoravelmente, proporcionando cada vez melhores resultados e possibilitando a aplicação de processos de extração de informação a áreas que exigem uma maior exatidão posicional, como é o caso da cartografia de base topográfica.

1.2 - DELIMITAÇÃO DO TEMA

A produção cartográfica de acordo com as normas de aquisição do CIGeoE, inclui um vasto número de entidades geográficas a serem representadas cartograficamente. Neste projeto, decidimos restringir o estudo a duas entidades geográficas: edificado habitacional (casas) e rede viária, sendo que esta última irá recair sobre estradas asfaltadas (com cobertura de alcatrão).

Todo o estudo terá como referência a informação proveniente de processos de restituição fotogramétrica do Centro de Informação Geoespacial do Exército (CIGeoE).

Surge então a questão principal à qual se pretende dar resposta:

“A classificação de imagens multiespectrais terá a precisão suficiente para dar resposta às necessidades da cadeia de produção cartográfica do CIGeoE?”

Agregada a esta questão surgem questões derivadas para as quais também se pretende obter resposta:

“Os resultados obtidos justificam uma mudança da forma de operar da cadeia de produção?”

“No que respeita a custos de produção, será uma mais valia a aquisição de informação por classificação?”

“As árvores de decisão poderão ser adotadas universalmente para classificação de imagens provenientes do mesmo sensor?”

Todo o projeto será conduzido de forma a dar resposta às questões atrás referidas.

1.3 - MOTIVAÇÃO E OBJETIVOS

Sendo o CIGeoE por excelência o produtor oficial da cartografia de base em Portugal, e surgindo como um centro de investigação da área, é de especial interesse que os estudos efetuados permitam a sua aplicação na cadeia de produção, sendo que, tais estudos podem trazer benefícios em termos de custos associados ao processo de aquisição de informação.

A deteção remota é uma das áreas que se encontra menos explorada na cadeia de produção cartográfica, pelo facto do processo de aquisição de dados fotogramétrico para a produção de cartografia à escala 1:25000, ser um processo de produção com resultados de elevada qualidade cartográfica. Contudo com o crescente aumento da resolução espacial das imagens de satélite e da progressiva diminuição dos custos da sua aquisição, é pertinente equacionar a possibilidade de tentativamente substituir os processos de produção de cartografia topográfica baseados em técnicas fotogramétricas, por abordagens de classificação de imagens multiespectrais de base espacial. Neste trabalho de projeto pretende-se efetuar um estudo técnico com incidência na avaliação da qualidade posicional, geométrica e semântica da cartografia gerada a partir de imagens multiespectrais de alta resolução.

O presente estudo irá assentar em duas vertentes, uma com imagens de satélite outra com ortoimagens provenientes de camaras aéreas a bordo de aeronaves, cada vertente é composta por três fases, em que na primeira fase será efetuada a classificação da imagem multiespectral com recurso a algoritmos de classificação supervisionada. A segunda fase diz respeito à criação de máscaras e filtragem do resultado obtido na classificação. Por fim a terceira fase com a passagem do resultado da fase anterior para o formato vetor, onde por processos de generalização e edição a informação será refinada de forma a obter um resultado semelhante ao definido como referência. No final de cada fase será efetuada uma avaliação de resultados, em que a primeira avaliação será efetuada com recurso a matrizes de contingência e a segunda comparando os resultados obtidos com os definidos como referência através da metodologia adotada para o efeito.

No final, será analisada a viabilidade de aplicação destes processos à cadeia de produção.

1.4 - ESTRUTURA DO TRABALHO DE PROJETO

O presente trabalho encontra-se estruturado em cinco capítulos, os quais se encontram subdivididos em subcapítulos e sequenciados de forma a dar um encadeamento lógico ao projeto. O primeiro capítulo diz respeito à introdução, onde são expostos os objetivos a cumprir assim como o enquadramento do projeto. No segundo capítulo é efetuada uma revisão de literatura onde são apresentados os mais recentes estudos na área da classificação de imagem. No terceiro capítulo são apresentados os dados de entrada, a área em estudo, assim como as metodologias adotadas para a análise do caso estudo. No quarto capítulo é

feita a apresentação de resultados e discussão dos produtos obtidos. Por fim no quinto capítulo são tecidas algumas conclusões assim como propostas de estudo futuras.

CAPÍTULO 2

ESTADO DA ARTE

Desde sempre que o Homem sentiu a necessidade de mapear a superfície da Terra. Ao longo do tempo vários foram os processos utilizados para automatizar a extração de informação geográfica. A melhoria da resolução espacial e radiométrica dos sensores a bordo dos satélites a par do desenvolvimento de novos algoritmos, a deteção remota tem vindo a afirmar-se como uma efetiva alternativa aos processos tradicionais de elaboração de cartografia.

O projeto francês “*Système Probatoire d’ Observation de la Terre*” (SPOT), foi o primeiro sistema espacial destinado à produção de cartografia topográfica de escala média. O sistema era baseado num satélite com capacidade de efetuar gravação de dados stereo e capacidade de determinação da altitude com um erro médio quadrático (RMS) de 10m. O satélite possuía uma resolução de 10m para o sensor pancromático e uma resolução de 20m para o multiespectral [Welch, 1985]. Com esta resolução previa-se que pudesse ser extraída informação para escalas entre 1:250000 a 1:50000. Os resultados da classificação foram avaliados através de técnicas de amostragem sistemática e estratificada sistemática, uma técnica iterativa que faz uso de uma grelha de amostragem e uma tabela de números aleatórios correspondente, de forma a identificar a amostra, isto é, cada ponto da grelha tem um identificador correspondente na tabela.

A restituição automática de entidades geográficas a partir de uma imagem multiespectral é conseguida com algoritmos de classificação, segmentação de imagem e identificação automática de objetos, existindo vários algoritmos para o efeito.

Com o avanço tecnológico foram surgindo novas formas expeditas de identificação da ocupação de solo em imagens de satélite tais como o uso de índices de vegetação como o *Normalized Difference Vegetation Index* (NDVI), desenvolvido por Rouse et al. [1974] para a avaliação da vegetação. A utilização dos índices de vegetação permitiu à data a segmentação da biomassa em 6 classes, definidas por atributos biofísicos específicos, tendo sido utilizadas para o efeito de árvores de decisão com base no NDVI [Runing et al., 1995].

Esta abordagem abriu caminho a uma exploração de algoritmos de processamento de imagens, tendo vindo a aumentar o vasto leque de objetos passíveis de serem extraídos com recurso a imagens de satélite. Uma das técnicas utilizadas em 2003 para extração de vias de comunicação de uma imagem do satélite IKONOS foi o algoritmo da máxima verosimilhança. A resolução da imagem era de 6m para a imagem multiespectral e de 1m para a pancromática, sendo considerada uma imagem de alta resolução. Os resultados obtidos foram bastante satisfatórios tendo-se chegado à conclusão que para zonas urbanas o algoritmo era eficiente na extração de estradas principais e que para zonas rurais o mesmo era válido para toda a rede viária [Sue et al., 2003]. Embora esta abordagem para além de métodos de classificação

tenha utilizado outras técnicas, foi uma das primeiras abordagens à extração de objetos que não vegetação utilizando algoritmos de classificação.

Com as políticas de disponibilização de dados adotadas no seio da União Europeia (UE), tem-se tornado cada vez mais fácil o acesso a informação geoespacial, potencializando o desenvolvimento de vários algoritmos e ferramentas de processamento de imagens, pela utilização de aplicações de código aberto. [Kang, 2018]

Uma vez que no meio urbano a classe de objetos que tem mais impacto é o edificado, muitas são as aplicações desenvolvidas no sentido de extrair esse tipo de informação, sendo que as que fazem uso de nuvens de pontos LIDAR em complemento das imagens multiespectrais têm proporcionado bons resultados.

Gu et al. [2015], criou um novo modelo baseado no *Multiple Kernel Learning* (MKL) que se baseia no *Support Vector Machine* (SVM) e tem a capacidade de integrar um vasto número de dados, em que foram obtidas precisões na ordem do 85% para os vários modelos de classificação testados, sendo que o mesmo definiu uma ordem de significância para o conjunto de dados usado, tendo definido a informação espectral como a que mais influência a classificação de imagem [Gu, 2015].

A utilização de classificadores com recurso a técnicas de *machine learning* tem vindo assim suscitar cada vez mais interesse por parte dos investigadores, estando o mesmo relacionado com o grande volume de informação geoespacial disponibilizada.

As redes neuronais, em particular as *Convolutional Neural Networks* (CNN) são uma das formas de classificação que à semelhança do MKL fazem uso de algoritmos de *machine learning*, onde são fornecidos vários inputs ao sistema definidos como neurónios de entrada, de forma a possibilitar a aprendizagem do algoritmo. Yu et al. [2017], foi um dos investigadores que estudaram a aplicação de algoritmos deste tipo a zonas urbanas, tendo aplicado o mesmo algoritmo de aprendizagem a várias regiões e verificado que a qualidade dos resultados variavam de zona para zona. Concluiu que a variabilidade da qualidade dos resultados se devida à variação do número de dados usados no treino do classificador, levando a resultados bastante diferentes com precisões globais a variarem entre os 64% e 89%, resultados que se devem a diferentes níveis de aprendizagem causados por amostras diferentes [Yu, 2017].

Contudo, embora todas estas formas de classificação tenham atualmente grande impacto as mesmas requerem um grande volume de dados daí que algoritmos de classificação mais simples como o da Máxima Verosimilhança (MV) continuem a ser utilizados uma vez que proporcionam resultados bastante satisfatórios quando comparados com algoritmos que fazem uso de *machine learning*. O algoritmo da MV é uma boa ferramenta quando não se dispõe de um grande volume de dados de treino e quando o tempo de processamento é limitado.

Associado ao tempo de processamento surge uma outra forma de classificação bastante mais simples e com maior velocidade de processamento devido à simplicidade do algoritmo. As árvores de decisão (AD), mais especificamente árvores binárias, são uma forma simples de classificação que possibilitam a utilização de inúmeras variáveis, podendo tornar-se complexas se a certos nós da árvore forem aplicados outros algoritmos de classificação como SVM, passando a tomar a designação de AD híbrida, estas à semelhança do caso anterior são utilizadas em zonas onde existe um grande volume de dados [Friedl, 1997]. O algoritmo torna-se assim mais complexo passando para o âmbito do *machine learning* e diminuindo a velocidade de processamento de dados.

Várias aplicações foram posteriormente desenvolvidas utilizando algoritmos de classificação supervisionada e não supervisionada, árvores de decisão, segmentação e métodos de modelação espacial, sendo que de todos estes métodos o que ofereceu melhor precisão foi o de modelação espacial. Utilizando forma, textura, proximidade e contexto onde o objeto está inserido para resolver os problemas decorrentes da resposta espectral, este tipo de algoritmos designam-se de classificadores baseados em objetos, e á semelhança das técnicas de *machine learning*, está dependente da quantidade de dados existente, uma vez que quanto mais inputs o operador tiver melhor será a discretização a fazer do objeto, pelo facto de se poder criar mais atributos para definir a classe de objetos.

Já fora da área da classificação de imagem surgem cada vez mais técnicas de reconhecimento de objetos quer sejam eles de cariz natural ou artificial, utilizando métodos de segmentação como o *active contour*, Liasis et al. [2016], desenvolveram um estudo onde otimizaram o algoritmo para a deteção de edifícios, chegando à conclusão que o modelo proposto está dependente da homogeneidade espectral dos objetos a extrair, o modelo por este proposto é direcionado de forma a que o processamento evite zonas passíveis de criar falsos positivos mostrando-se eficiente com precisões de 93% [Liasis et al., 2016].

Com base em todos os estudos analisados não é possível afirmar qual o melhor algoritmo de classificação de áreas urbanas, contudo de acordo com a literatura verifica-se que os resultados obtidos estão diretamente relacionados com a área de estudo, sendo que quando se analisam áreas de aglomerados populacionais o ruído é maior, dando origem a falsos positivos.

Para a produção de cartografia de base topográfica embora a classificação de imagem proporcione bons resultados, existe a problemática da generalização e simplificação dos dados adquiridos, sendo que para escalas maiores que requerem uma maior definição do pormenor à necessidade de aumentar o volume de dados de forma a diminuir o ruído.

CAPÍTULO 3

DADOS E MÉTODOS

3.1 - CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A área em estudo diz respeito à região de Samora Correia, conselho de Benavente, distrito de Santarém, uma zona em que a agricultura é o seu principal pilar de desenvolvimento, e onde estão implantadas importantes empresas nacionais.

A área em estudo está inserida no retângulo que comporta toda a área urbana de Samora Correia assim como a área rural em seu redor, perfazendo uma total de 59 Km². A nível de relevo é uma área essencialmente plana, havendo uma representatividade de 77% de terra fértil e de 21% de superfícies artificiais. Esta área está enquadrada entre 2 cartas topográficas à escala 1:25000 série M888 do CIGeoE. Na figura 3.1 podemos verificar o enquadramento da área de trabalho a nível geral, pelo seu posicionamento no território nacional e num nível mais detalhado pelas freguesias que a enquadram assim como o limite da imagem trabalhada.

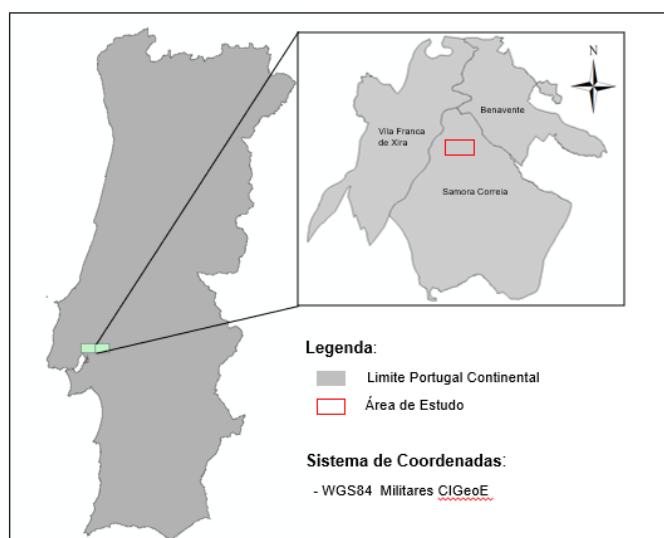


Figura 3.1 – Enquadramento da Área de Estudo

No que respeita às classes de ocupação do solo a restituir, esta área comporta desde áreas artificializadas, a zonas hidrográficas e vegetação, onde há um conjunto de culturas que podem ser exploradas e cartografadas de forma diferente.

3.2 - DADOS UTILIZADOS

Uma vez que a nível de delimitação do projeto o mesmo está direcionado para objetos artificializados, é de todo o interesse trabalhar com imagens com a máxima resolução espacial, de forma a obter resultados comparáveis com a referência. Para o efeito foram utilizadas imagens com uma resolução espacial de 0.5m, esta resolução é resultado de um processo de *pansharpening* efetuado pela entidade que disponibilizou a informação. A nível espectral as imagens têm quatro bandas, três no visível e uma no infravermelho.

3.2.1. Imagem Satélite

As imagens de satélite utilizadas neste projeto foram adquiridas pelo satélite GeoEye-1, que foi lançado a 6 de setembro de 2008 e está incluído na classe de satélites de alta resolução.

A tecnologia a bordo do mesmo é considerada a mais sofisticada em satélites comerciais, tendo a capacidade de produzir um total de 350.000Km²/dia. Está colocado a uma altitude de cerca de 681Km e tem um período de revisita de menos de 3 dias.

A tabela 3.1 descreve a informação relativa do sensor da imagem satélite utilizada

Tabela 3.1— Imagem de Satélite.

Satélite	GeoEye 1	
Resolução Espacial	Pancromática	0.46m
	Multiespectral	1.84m
Resolução Espectral	Pancromática	450-800nm
	Blue	450-510nm
	Green	510-580nm
	Red	655-690nm
	NIR	780-920nm

3.2.2. Ortoimagem

A ortoimagem utilizada no projeto foi produzida durante a elaboração do trabalho. Para o efeito, foram coordenados pontos fotogramétricos na zona de estudo, tendo sido efetuados os respetivos trabalhos de campo. Para a geração da ortoimagem foi utilizado o software MATCH-AT para efetuar a triangulação aérea e posteriormente o OrthoMaster e o OrthoVista para a produção da ortoimagem e do mosaico final da área de estudo.

Embora a imagem criada tenha sido orto retificada não representa um verdadeiro orto, uma vez que para tal teria de se dispor de um MDS, para que fossem efetuadas as respetivas correções às distorções causadas pela câmara.

Na geração das ortoimagens foram definidos parâmetros que permitissem uma maior resolução radiométrica da imagem, tendo-se optado por não comprimir a imagem e gerar ortoimagens de 16bits. Uma vez que o objetivo do projeto se prende com a aquisição de objetos referentes à malha urbana, foram também efetuados alguns ajustamentos nesse sentido, a tabela 3.2 resume algumas das características do sensor utilizado na aquisição das imagens.

Tabela 3.2 – Parâmetros da imagem aérea adquirida pela câmara UltraCam – XPWa

Câmara	UltraCam-XpWa
Resolução Espacial	0.5m
Bandas	Red
	Green
	Blue
	NIR
Data do Voo	03/06/2014

3.2.3. Dados Vetoriais

Os dados vetoriais disponibilizados pelo CIGeoE dizem respeito às folhas 1:25000, números 404 e 405 da série M888, encontrando-se toda a informação referente aos mesmos na tabela 3.3.

Tabela 3.3 – Dados Vetoriais

	Folha 404	Folha 405
Série	M888	M888
Escala	1:25000	1:25000
Nome	Alverca do Ribatejo	Santo Estevão (Benavente)
Edição	5 IGeoE 2009	3 IGeoE 2007
Trabalhos de Campo	2008	2005
Sistema de Coordenadas	UTM WGS84 MILITARES	UTM WGS84 MILITARES

3.3 - MÉTODOS

De forma a efetuar uma análise comparativa de vários tipos de produtos foram aplicados alguns algoritmos de classificação de imagem utilizados em detecção remota, a Máxima Verossimilhança (MV), o *Support Vector Machine* (SVM) e por último, as Árvores de Decisão (AD). No processamento de dados foi utilizado software ENVI da *Harris Geospatial* e o ArcMap 10.6.1 para generalização da informação adquirida.

A metodologia de análise tem várias fases sendo que no final de cada fase é efetuada a avaliação do resultado obtido. Na figura 3.2 é apresentada a metodologia adotada.

Esta metodologia foi assim aplicada aos três classificadores referidos, sendo efetuado um enquadramento teórico dos mesmos nos próximos subcapítulos.

De igual forma será efetuado um enquadramento semelhante para a fase de simplificação/generalização da informação vetorial adquirida, onde será efetuada a apresentação das ferramentas aqui utilizadas assim como a metodologia adotada pelas mesmas, sendo por fim reservado um subcapítulo para a exposição dos métodos adotados na avaliação de cada fase.

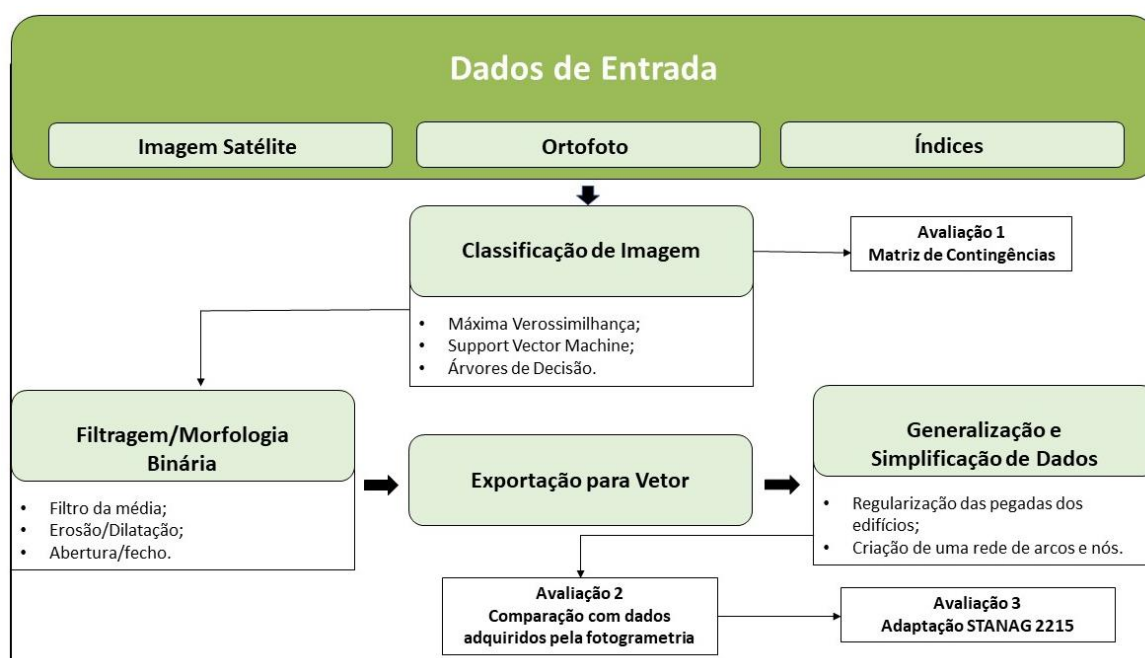


Figura 3.2 – Metodologia Adotada

3.3.1. Algoritmos de Classificação Supervisada

Os algoritmos de classificação supervisionada paramétricos fazem uso de áreas de treino para calcular parâmetros estatísticos que caracterizem cada uma das classes previamente definidas. Os algoritmos de classificação supervisionada não paramétricos recorrem a outras métricas ou padrões para caracterizar as classes. Neste projeto foram definidas 6 classes de ocupação do solo: água, asfalto, edificado habitacional (EH), sombra, solo nu e verde, para as quais foi selecionada uma amostra significativa da área de estudo que serviu de input aos algoritmos de classificação.

Na figura 3.3 é possível visualizar a dispersão das classes de ocupação do solo identificadas para treino do classificador, bem como o código de cores atribuído.

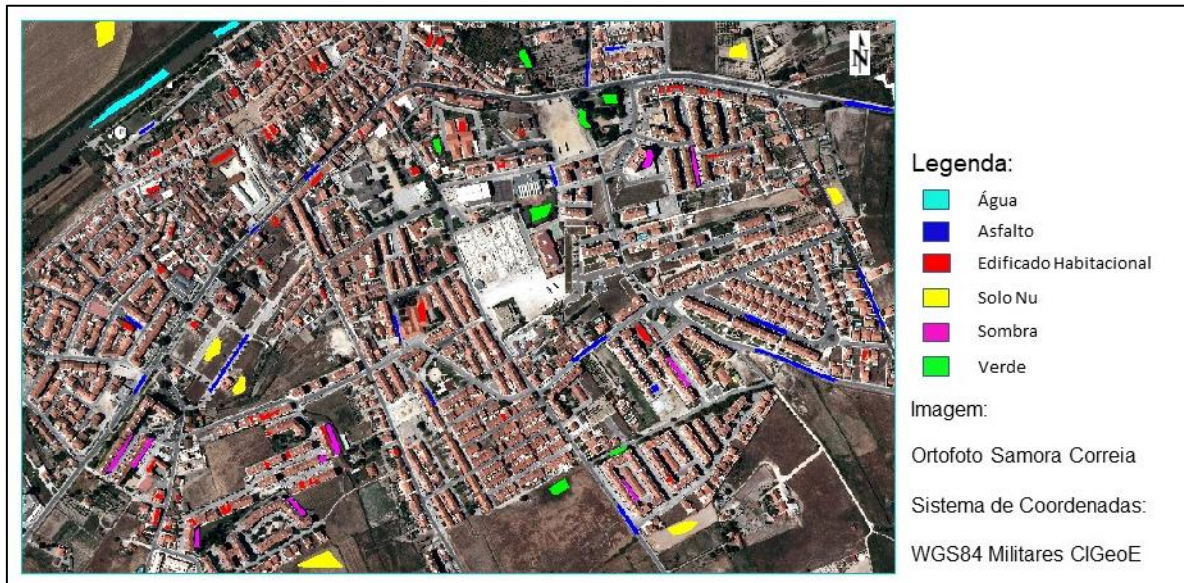


Figura 3.3 – Áreas de Treino

Embora as áreas apresentadas sejam referentes à ortofotografia gerada, foram criadas áreas iguais para a imagem satélite, com a exceção da classe sombra que devido ao ângulo de elevação do sol ser diferente, levou à identificação de zonas de sombra distintas para treino. Na definição das áreas de treino teve ainda de se ter em conta que para o objeto do tipo casa existem várias respostas espectrais, pelo que esta classe tem de ser decomposta em várias subclasses de forma a proporcionar melhores resultados.

Para a classificação supervisionada aplica-se a metodologia apresentada na figura 3.4

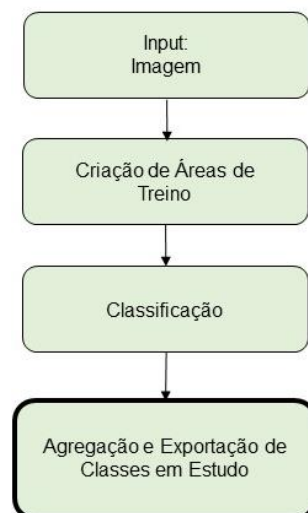


Figura 3.4 – Metodologia Classificação Supervisada

3.3.1.1. Máxima Verosimilhança (MV)

A classificação por MV insere-se nos métodos de classificação supervisionada e decorre do teorema de Bayes, que assume uma distribuição normal dos dados para calcular a média e desvio padrão de uma amostra de dados de cada classe. A determinação da classe w_i à qual um pixel na posição \mathbf{x} pertence é uma probabilidade condicional: [Catalão, 2018]

$$p(w_i | \mathbf{x}), i=1,..M$$

Probabilidade de ser classe w_i dada a posição \mathbf{x} . A classificação é feita de modo que:

$$\mathbf{x} \in w_i \quad \text{se} \quad p(w_i | \mathbf{x}) > p(w_j | \mathbf{x}) \quad \text{para todos os } j \neq i$$

Usando o Teorema de Bayes e simplificando a expressão, a probabilidade do pixel \mathbf{x} pertencer á classe w_i pode ser escrita como:

$$\mathbf{x} \in w_i \quad \text{se} \quad g_i(\mathbf{x}) > g_j(\mathbf{x}) \quad \text{para todos os } j \neq i$$

em que:

$$g_i(x) = \ln p(w_i) - \frac{1}{2} \ln \left| \sum_i \right| - \frac{1}{2} (x - m_i)^t \sum_i^{-1} (x - m_i) \quad (3.1)$$

Em que m e \sum correspondem ao vetor da média e a matriz covariância dos dados da classe w_i .

Os pixéis são atribuídos à classe com maior probabilidade e não classificados se o seu valor estiver abaixo do limiar de probabilidade definido pelo utilizador.

Deste modo, para que haja uma maior precisão do método, a amostra utilizada para cada classe deverá conter um elevado número de pixéis, sem nunca comprometer os resultados finais uma vez que também têm de ser criadas áreas de validação.

A figura 3.5 procura expor como são classificados os pixéis através deste método, onde a probabilidade de cada pixel pertencer a uma classe depende do tamanho, da proximidade ao centro e da forma da classe no domínio espectral.




Figura 3.5 – Funcionamento do algoritmo MV (Fonte: <https://rpubs.com/hudsonchavs/maxverosimilhanca>)

3.3.1.2. Support Vector Machine

O algoritmo SVM foi formulado por Boser, Guyon, e Vapnik em 1992 [Awad et al.,2015], é considerado um algoritmo de classificação não paramétrico, sendo uma adaptação do *Support Vector Clustering*, foi concebido para dar resposta a problemas de regressão e classificação, contudo a sua maior aplicação é à classificação de amostras. [Ben-Hur, 2001]

É designado como um classificador supervisionado, e por muitos considerado como um algoritmo de *machine learning*, este classificador tem como principal objetivo a determinação de um hiperplano ótimo, isto é, de todos os hiperplanos possíveis capazes de separar uma determinada amostra que dista a margem máxima definida, ou seja, o que oferece um maior grau de confiança de forma a obter uma classificação mais fiável. A figura 3.6 pretende dar a noção de hiperplano ótimo e a forma como os pixéis/amostra é classificada.




Figura 3.6 – Hiperplano ótimo SVM [Fonte: <http://svm.michalhaltuf.cz/support-vector-machines/>]

Os hiperplanos podem ser definidos em \mathbb{R}^N , onde n corresponde à dimensão da amostra, sendo o hiperplano definido pela seguinte fórmula [Awad et al.,2015]:

$$g(x) = w^t x + b \quad (3.2)$$

a distância entre as duas classes w_1 e w_2 é dada por [Awad et al.,2015]:

$$\frac{|g(x)|}{||w||} \quad (3.3)$$

sendo que o objetivo do SVM é calcular w e b de forma a que a $g(x)$ toma o valor -1 ou 1 consoante classe w_1 ou w_2 , entrando-se num problema de otimização, onde pela soma da função objetivo com os vários constrangimentos pesados chegamos à função de Lagrange que resolve o problema [Awad et al.,2015]:

$$\mathcal{L}(w, b, \lambda) = \frac{1}{2} w^t w - \sum_{i=1}^N \lambda_i [y_i (w^T x_i + b) - 1] \quad (3.4)$$

em que w diz respeito ao vetor de parâmetros, b uma constante e λ_i aos coeficientes de Lagrange.

A fórmula 3.4 é aplicada a amostras com maior grau de separabilidade onde se pretende encontrar a maior distância que separa as classes estudadas. Contudo, existem casos de amostras bastante homogêneas pelo que há uma necessidade de reformulação do problema, sendo introduzido um novo

parâmetro C designado de termo de regularização, quanto maior este termo menor será a distância entre classes, isto é menor será a distância apresentada na equação 3.4, quanto menor for o C maior a distância admitida e maior a possibilidade de surgirem falsos positivos na classificação.

No que respeita à aplicação prática, este como um classificador supervisionado tem a necessidade de dados de treino não existindo a possibilidade de o generalizar globalmente.

3.3.2. Classificação por Árvores de Decisão

As árvores de decisão no geral são definidas como uma estrutura de dados não lineares, e são constituídas por vários nós designados por subárvores, associado às árvores surge uma série de definições, que se apresentam na tabela 3.4.

Tabela 3.4 – Terminologia das Árvores [Neto, 2010]

Árvores de Decisão -Terminologia	
Pai	Cada nó é pai dos nós que se encontram após este
Descendentes	Nós que se encontram ligados ao pai
Folha	Nó sem filhos
Nó interior	Nó que não é raiz nem folha
Grau/Aridade	Corresponde ao número de filhos desse nó

Agregado ao conceito de árvore surge o de árvore binária do qual resultam novas terminologias que devem ser apreendidas para uma melhor compreensão da sua aplicação. Uma árvore binária tem como característica específica ter grau dois, e é dita equilibrada se a diferença de alturas das subárvores for inferior a 1, é considerada cheia se as duas subárvores tiverem a mesma altura, completa se estiver cheia até ao nível $h-1$, onde h designa a altura, e designada estritamente binária se todos os nós tiverem grau 0 ou 2. [Neto, 2010]

A figura 3.7 apresenta o caso de uma árvore estritamente binária completa e equilibrada.




Figura 3.7 – Árvore Binária [Fonte:Neto, 2010]

No caso da classificação de imagem aos nós interiores correspondem as expressões que definem a informação a que cada classe pertence, isto é, onde se inserem as expressões responsáveis pela separação

da informação e as folhas às respectivas classes. A este caso específico de árvores designamos também de árvore de decisão, terminologia que será adotada neste projeto.

Este método está associado a uma das questões de partida do projeto:

“As árvores de decisão poderão ser adotadas universalmente para classificação de imagens provenientes do mesmo sensor?”

A ser comprovada esta preposição, pode chegar-se a uma forma de classificação de imagem bastante simples, rápida (não sendo necessário um elevado número de dados de treino como é o caso dos algoritmos de *machine learning*) e menos exigente no que respeita a recursos computacionais.

Como ponto de partida para a definição dos nós da árvore de decisão, a imagem foi segmentada tendo-se aplicado para esse efeito o algoritmo ISODATA. Este método de classificação tem por base o cálculo das médias das classes distribuídas uniformemente no espaço, agrupando os pixéis iterativamente através de técnicas de distância mínima, todos os pixéis são classificados para a classe mais próxima a menos de um determinado limite, quer a nível de desvio padrão quer a nível de distância máxima. [Harris, 2019]

O resultado desta classificação é utilizado para definir o número de nós a criar na AD, correspondendo cada nó a uma classe ISODATA, isto é, as classes criadas pelo algoritmo ISODATA apenas servem para agrupar pixéis com resposta radiométrica semelhante, por sua vez a AD irá fazer uso dessas classes para criar limiares de decomposição a partir dos quais são criadas as classes de objetos definidas.

Uma vez que para a definição de um limiar para cada classe em muitos dos casos a informação constante nas bandas da imagem não é suficiente, foram criados índices para auxiliar nesta tarefa, tais como NDVI, índice desenvolvido por Rouse et al. [1974], sendo a principal aplicação deste a determinação de áreas verdes. Este índice é calculado através da aplicação da seguinte fórmula:

$$NDVI = \frac{NIR - Red}{NIR + Red}, \quad (3.5)$$

O cálculo deste índice tem por base a forte absorção de parte da luz visível pelas plantas para comprimentos de onda entre 620 e 700 nm correspondente ao vermelho, (radiação utilizada no processo de fotossíntese) e a reflectância da radiação entre os 700 e 1100 nm referente ao NIR. Este embora seja utilizado para discretização de vários tipos de objetos, [Zhou et al, 2012], as suas aplicações são maioritariamente para fins de identificação de vegetação, variando o valor deste no intervalo de [-1; 1], sendo que quanto mais próximo de 1 maior a probabilidade de ser vegetação.

Para além do NDVI foi também utilizado o índice denominado de *Red Roof Remove* (RRR) [Petrila, 2015], que embora o autor o denomine de índice experimental, para o caso estudo revelou-se uma ferramenta crucial. Este índice faz uso apenas da região visível e na sua fórmula é utilizada informação respeitante a comprimentos de onda entre os 446 e os 500nm (azul) e 620 e 700nm (vermelho) pela aplicação da seguinte fórmula:

$$RRR = \frac{Red - Blue}{Red + Blue}, \quad (3.6)$$

No que respeita à metodologia adotada neste método de classificação é bastante diferente dos casos anteriores, a figura 3.8 expõe a forma como esta foi efetuada.

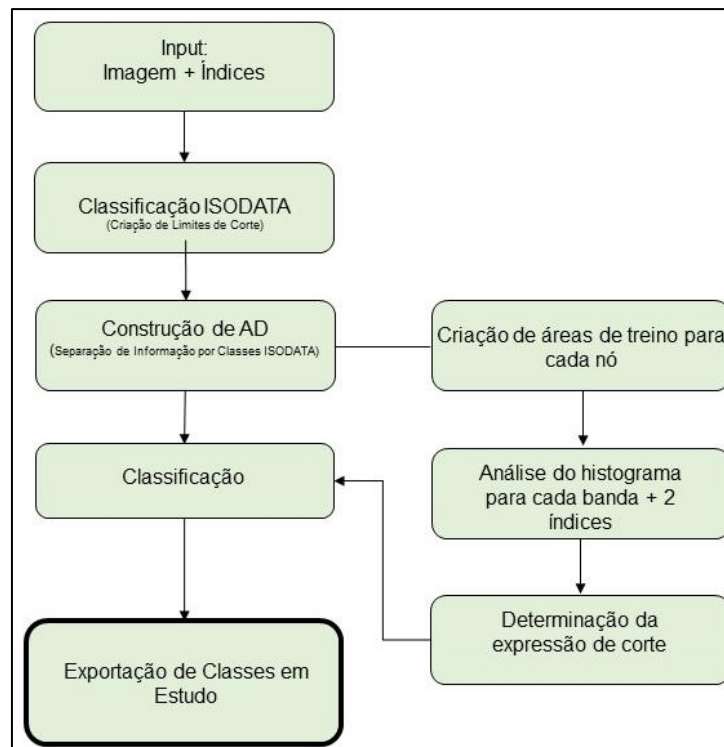


Figura 3.8 – Metodologia AD

3.3.3. Filtragem e Morfologia Binária

Esta é uma fase intermédia entre a classificação e vectorização que tem como principal objetivo a eliminação do ruído causado por classes com resposta espectral semelhante. Para que o mesmo seja eliminado/atenuado é necessário efetuar operações de transformação morfológica e de filtragem.

Este tipo de transformações são geralmente implementadas por um elemento estruturante, que não é mais que um caso particular de imagem binária que ao ser aplicada vai interagir com o conjunto de dados de entrada, a figura 3.9 representa um elemento estruturante 3x3.

1	1	1
1	1	1
1	1	1

Figura 3.9 – Elemento Estruturante

As operações morfológicas utilizadas no projeto foram a erosão, dilatação, abertura e fecho. Conforme o conjunto de dados de entrada vão sendo conjugadas com outros operadores, de forma a chegar aos melhores resultados, a fim de facilitar o processo de generalização vetorial.




Figura 3.10 – Dilatação (b) e Erosão (c) da Imagem (a) [Fonte: Soares, 2018]

A figura 3.10 representa as operações de dilatação e erosão respectivamente para uma figura inicial. No que respeita às operações de abertura e fecho as mesmas consistem na aplicação sucessiva das anteriores, isto é, a abertura consiste em dilatar o resultado da erosão e o fecho consiste em erodir a dilatação. Para além das transformações em alguns casos foi utilizado um filtro da média.

Todas estas operações consoante os resultados da classificação eram aplicadas segundo uma determinada sequência.

3.3.4. Transformação e Tratamento de Informação Vetorial

Como já foi referido o tratamento de toda a informação vetorial foi efetuado com o software ArcMap 10.6.1, tendo sido utilizadas ferramentas específicas para esse efeito.

A necessidade de efetuar generalização de objetos segundo a literatura prende-se com alguns fatores que têm de ser tidos em conta nas ferramentas a utilizar, são eles: congestionamento de informação, conflito, agregação, inconsistência e impercetibilidade. [Shea, 1989]

Deste modo, uma vez que no presente trabalho tratamos dois tipos de objetos, edificado habitacional e vias, a abordagem adotada está esquematizada na figura 3.11.

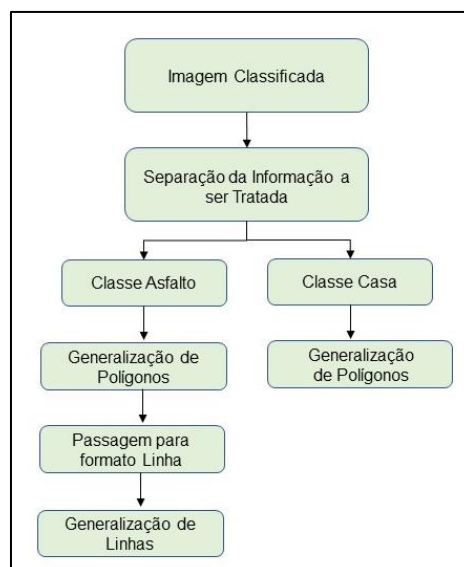


Figura 3.11 – Tratamento de Informação Vetorial

Uma vez que para cada classe são tratados objetos com geometrias diferentes optou-se por expor todo o processo metodológico em subcapítulos diferentes.

3.3.4.1. Generalização da Classe Edificado Habitacional

A necessidade de aplicação de ferramentas de generalização e simplificação justifica-se pelo facto da informação adquirida, embora tenha sido tratada por operadores morfológicos, se encontrar extremamente pixelizada como podemos visualizar na figura 3.12, isto é, devido à resolução geométrica de cada pixel (0,5m) os vários objetos apresentam uma geometria bastante irregular, havendo a necessidade de regularizar o vetor extraído pelo classificador.




Figura 3.12 – Exemplo do resultado da classificação para a classe Edificado Habitacional

Deste modo, torna-se necessário a aplicação de ferramentas que regularizem a informação adquirida, nos próximos subcapítulos será efetuado o enquadramento das ferramentas utilizadas.

a) *Regularize Building Footprint/ Simplify Building*

Esta ferramenta tem como principal objetivo remover o aspeto irregular das linhas criadas no processo de classificação, como podemos verificar na figura 3.13.




Figura 3.13 – Regularização de Edifícios [Fonte: ArcGis 10.6 Help]

A ferramenta tem por base um algoritmo de compressão de linhas, o funcionamento deste tem por base a deteção da linha que satisfaz as condições impostas pelo utilizador, de forma a chegar a um polígono regular, quer seja ele composto por linhas retas ou curvas, simplificando assim o processo de edição [Gribov, 2018].

Existe assim a possibilidade de escolher alguns métodos de processamento, tais como a utilização dos ângulos retos, ângulos retos e diagonais, não fazer uso dos anteriores e utilização de círculos no caso de superfícies curvas, consoante o método utilizado vão surgindo parâmetros específicos a definir pelo utilizador.

No que respeita à ferramenta *Simplify Building* é utilizada após a execução do processo anterior com o objetivo de regularizar os espaços criados de forma incorreta nas arestas dos polígonos, sendo visível na figura 3.14 o seu funcionamento.




Figura 3.14 – Simplificação de Edifícios [Fonte: ArcGis 10.6 Help]

b) Aggregate Polygon

A utilização desta ferramenta justifica-se com a imposição de regras de aquisição de dados para a cartografia 1:25000 do CIGeoE documentadas nas normas de aquisição de informação com o objetivo de fornecer uma abordagem lógica e consistente da aquisição de informação geoespacial.

Deste modo, com a aplicação desta ferramenta há a possibilidade de agregar edifícios a menos de 3m assim como eliminar espaços vazios com menos de 100m² no interior de um polígono como é especificado nas normas. Este é um algoritmo de agregação básico onde o utilizador define o limite até ao qual deve existir agregação, havendo a possibilidade de inserir restrições de não agregação implementadas através de barreiras definidas por informação proveniente de outras layers como rede viária e verdes.

Contudo a agregação efetuada pelo algoritmo não é uma agregação de “consciência”, ao contrário da elaborada pelo operador de fotogrametria a quem cabe a capacidade de decisão de agregar ou não determinado polígono.

Para uma maior fluidez do processamento era conveniente chegar a um modelo onde os parâmetros já se encontrassem definidos a priori, contudo o mesmo não foi possível uma vez que a forma como os edifícios se encontram no terreno altera de zona para zona, isto é, há zonas que seguem um ordenamento regular e outras em que os edifícios aparecem aglomerados de forma desordenada levando a que os parâmetros de generalização sofra alterações dependendo da zona, não tendo sido encontrados parâmetros que se apliquem globalmente.

3.3.4.2. Generalização da Classe Asfalto

No que respeita à generalização das áreas criadas pelo classificador para a classe asfalto, todo o processo será direcionado para a passagem da informação adquirida em formato polígono para formato linha, sendo que geometricamente essa terá de corresponder à linha que passa pelo eixo do polígono.

Desta forma foram utilizadas as ferramentas apresentadas de seguida, que consistem na aplicação de vários operadores.

a) Polygon to Central Line

Esta aplicação agrega duas ferramentas o *create skeleton* e *trim skeleton*, sendo que o output da primeira serve como input para a segunda, a ferramenta processa os polígonos que lhes são

dados como input, criando uma série de polígonos de *Thiessen* de tal forma que o polígono inicial é esqueletizado, sendo que a segunda ferramenta vai eliminar as ramificações anteriores consideradas desprezíveis.

Para otimização dos resultados há a necessidade de ajustar o parâmetro distância à amostra.




Figura 3.15 – Criação da Rede Viária, a) após esqueletização, b) após eliminação de ramos desprezíveis

Na figura 3.15 é apresentado o resultado da passagem de um polígono proveniente do processo de classificação para a linha central, através da aplicação da ferramenta exposta anteriormente. Na figura da esquerda o processo de esqueletização onde são criados polígonos de Thiessen e determinada a linha central do polígono e na figura da direita é mostrada a passagem da ferramenta que elimina as ramificações desprezíveis, sendo visíveis algumas ramificações que podem ser eliminadas com o ajuste dos parâmetros de entrada.

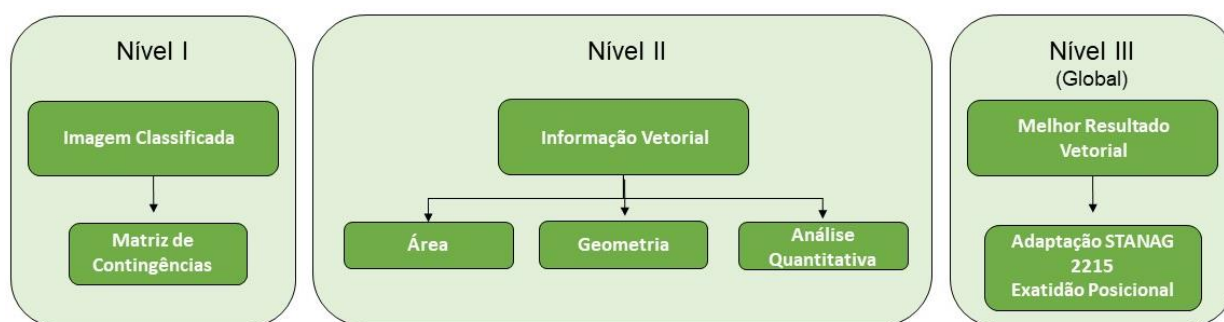
b) *Simplify Line*

Esta ferramenta foi configurada para operar utilizando a opção remoção de pontos, que tem por base o algoritmo *Douglas Peucker*, onde através de uma tolerância definida pelo utilizador o algoritmo remove os vértices considerados insignificantes de forma a tornar a linha mais regular e com um aspeto mais suavizado.

A tolerância deverá ser definida de forma cuidada uma vez que esta pode levar a uma remoção excessiva do número de vértices e por conseguinte levar a uma alteração relativa entre a linha e os objetos adjacentes, desta forma a estrutura topológica deverá ser sempre mantida. [Matos 2001]

3.3.5. Avaliação e Validação de Informação

A avaliação do resultado final processa-se em três níveis, ao nível raster ou imagem, onde é avaliado o resultado final da classificação, ao nível vetorial, onde é avaliada a qualidade da informação extraída da classificação em formato vetorial por comparação com a existente extraída por outros processos (fotogrametria) e ao nível global onde se avalia a exatidão posicional do melhor resultado obtido por adaptação do STANAG 2215.

**Figura 3.16** – Processo de Avaliação

Na figura 3.16 é exposta a forma como se processa cada avaliação no respetivo nível, sendo que nas secções subsequentes será descrito de forma detalhada a metodologia adotada para cada nível.

3.3.5.1. Avaliação Nível I

Nesta fase de avaliação pretende-se verificar o grau de conformidade da classificação obtida através de cada um dos métodos atrás descritos com a verdade do terreno. Para o efeito, são adquiridas amostras das 6 classes na imagem multiespectral, diferentes das áreas de treino, utilizadas como input para o validador.

É assim criada uma tabela de contingências onde se avalia os pixéis que na amostra de validação estão corretamente e incorretamente classificados. São identificados dois tipos de erros, comissão e omissão, os primeiros dizem respeito aos pixéis que foram atribuídos a uma classe que não pertenciam, sendo vistos como um excedente na classe, o segundo tipo diz respeito a pixéis atribuídos a uma classe que foram erradamente classificados como pertencendo a uma outra.

Tabela 3.5 – Matriz de Contingências

		Classes Conhecidas (i)					
		AG	AF	EH	SN	SB	VD
Classificação Obtida (j)	AG						
	AF						
	EH						
	SN						
	SB						
	VD						
AG – Água		EH – Edificado Habitacional		SB - Sombra			
AF – Asfalto		SN – Solo Nu		VD - Verde			

Sendo que:

$$\text{Precisão Global} = \sum E_{ii} / \sum_{i=1}^N \sum_{j=1}^N E_{ij}, \quad (3.7)$$

A precisão global corresponde ao somatório da diagonal principal da matriz de contingências a dividir pelo somatório do total de pixéis de avaliação. Assim sendo quanto mais significativa for a amostra de avaliação, tendo em conta que a amostra não pode ser coincidente com a amostra de treino, mais fiável será o resultado obtido através desta matriz [Catalão, 2018].

Ainda baseado nesta matriz é utilizado neste nível o cálculo do índice kappa (k), que nos dá o nível de concordância entre o resultado da classificação e as áreas de validação criadas para as várias classes.

$$k = \frac{N \sum_{i=1}^N m_{ii} - \sum_{i=1}^N (G_i C_i)}{N^2 - \sum_{i=1}^N (G_i C_i)} \quad (3.8)$$

Onde, N corresponde ao número total de pixéis classificados, i corresponde ao número da classe, m_{ii} corresponde ao número de pixéis bem classificados por cada classe i, C_i corresponde ao número total de pixéis classificados na classe i e G_i corresponde ao número total de pixéis das áreas de validação para a classe i. Quanto mais próximo de 1 for o valor de k, maior o nível de concordância da classificação. [Navarro, 2018].

De forma a avaliar o valor do índice atrás referido foi adotada a tabela (3.6), adaptada de Landis et al. [1977].

Tabela 3.6 – Avaliação do Coeficiente (k)

Coeficiente k	Concordância
0.00-0.20	Muito Baixa
0.21-0.40	Baixa
0.41-0.60	Moderada
0.61-0.80	Boa
0.81-1.00	Muito Boa

No caso da classificação por árvores de decisão, uma vez que foi efetuada uma “compartimentação” da imagem inicial, e o resultado da matriz de contingências poderá não refletir uma avaliação justa, para este algoritmo além da avaliação através da matriz de contingências para a área de estudo, o algoritmo será aplicado a uma zona distinta e analisado o resultado obtido.

Após a análise Nível I, com base nos resultados obtidos nos vários métodos, é escolhido o que oferece melhor resultado de forma a continuar o processo estabelecido anteriormente.

3.3.5.2. Avaliação Nível II – Edificado Habitacional

A avaliação nível II é efetuada após a generalização e simplificação da informação classificada, onde estamos perante o produto final do processo proposto. Nesta fase, é efetuada a comparação da informação adquirida por processos classificativos e adquirida via fotogrametria.

Uma vez que a área de estudo não é homogênea, no que se refere à forma como o edificado está disposto no terreno, há a necessidade de dividir esta avaliação em duas vertentes, uma para a parte regular outra para a irregular.

No que reporta à avaliação da área irregular a avaliação passou apenas pela análise visual dos edifícios, através da criação de uma amostra e análise caso a caso, sem partir para uma análise de geometria mais aprofundada. Para o efeito foi aplicada a uma tabela comparativa com os itens apresentados na figura 3.17.

Análise Comparativa					
Id Polígono Referência	Nº de Polígonos Classificados para Definir a Referência	Área Coberta pela Referência	Área Coberta Pela Classificação	Geometria	Diferença de Áreas

Figura 3.17 – Itens a avaliar, Nível II EH Regular/Irregular

A nível da geometria é atribuída a seguinte escala:

- Geometria correta: 1
- Geometria parcialmente correta: 2
- Objeto adquirido de forma incorreta: 3

No que respeita aos objetos do tipo EH regular foi feita a seguinte avaliação:

- Análise visual do número de edifícios que foram corretamente adquiridos (criação de uma amostra aleatória da área) e análise caso a caso (idêntico ao EH irregular);
- Avaliação da área coberta;
- Análise estatística tendo por base uma amostra dos vértices constituintes.

Desta forma para a área regular seguiu-se a metodologia de processamento apresentada na figura 3.18. A figura 3.18 expõe de forma clara o modo de processamento e preparação da informação para ser avaliada, após o processamento a tabela é exportada para Excel e são calculadas as estatísticas para avaliação Nível II.

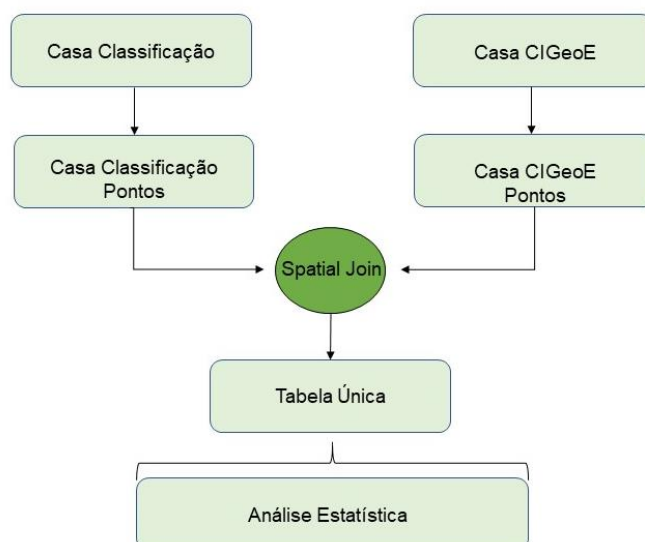


Figura 3.18 – Processamento de informação, avaliação Nível II-EH Regular

3.3.5.3. Avaliação Nível II – Asfalto

A avaliação nível II da classe asfalto resulta da comparação entre o somatório de todos os elementos lineares adquiridos, por cada classificador assim como a criação de uma amostra de pontos criada por intersecção espacial entre o resultado final do processo para a classe e o ficheiro resultante da aquisição manual por operadores fotogramétricos, designado de referência.

A figura 3.19 ilustra o processo de avaliação para esta classe.

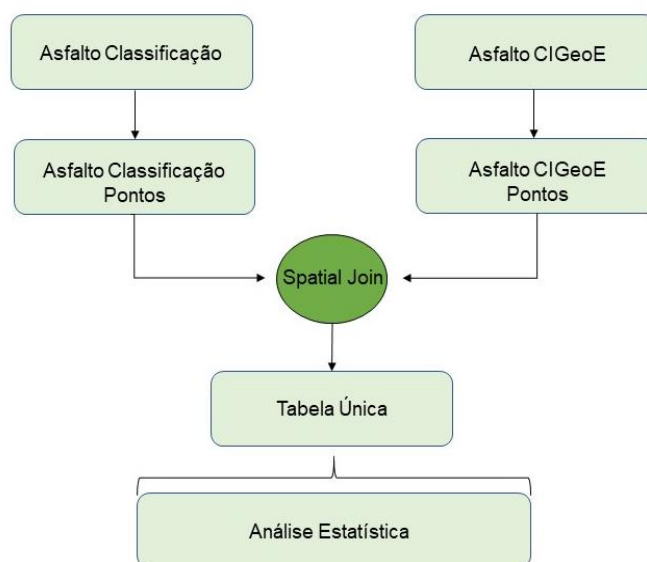


Figura 3.19 – Processamento de Informação Avaliação Nível II-Asfalto

3.3.5.4. Avaliação Global

A avaliação global resulta de uma adaptação ao STANAG 2215, onde iremos avaliar em termos de exatidão posicional o ficheiro que obteve melhores resultados da avaliação anterior, desta feita será tomado como referência o ficheiro de dados adquiridos via restituição fotogramétrica pelo CIGeoE, substituindo os dados que deveriam ser adquiridos com GNSS no terreno, sendo para o efeito considerados os vértices da amostra de casas já utilizado anteriormente.

Uma vez que o resultado obtido carece de informação altimétrica apenas será calculado o parâmetro CMAS (*Circular Map Accuracy Standarts*), calculado pela aplicação da fórmula 3.9.[Drobnjak, 2018]

$$CMAS = \sigma_c \left[1.2943 + \sqrt{\left(\frac{d}{\sigma_c}\right)^2 + 0.7254} \right] \quad (3.9)$$

Onde σ_c representa o desvio padrão da amostra para um nível de confiança de 39.35% e é dado pela equação 3.10.

$$\sigma_c = \sqrt{\frac{(\sigma_E)^2 + (\sigma_N)^2}{2}} \quad (3.10)$$

Sendo que σ_E e σ_N corresponde respetivamente ao desvio padrão da diferença das coordenadas cartográficas (Este, Norte). E d corresponde ao cálculo da média do vetor de desvio, calculado pela fórmula 3.11.

$$d = \sqrt{(\sigma_E)^2 + (\sigma_N)^2} \quad (3.11)$$

Após o cálculo do CMAS confronta-se esse valor com a tabela 3.7, que nos dá informação da cartografia possível de elaborar em função do valor de CMAS.

Tabela 3.7 – Classificação em termos de Precisão Horizontal Absoluta [adaptado de Mira, 2008]

Classificação	Medida à Escala do Produto	Classificação CMAS				
		1:25000	1:50000	1:100000	1:200000	1:250000
A	0.5mm	12.5m	25m	50m	100m	125m
B	1.0mm	25m	50m	100m	200m	250m
C	2.0mm	50m	100m	200m	400m	500m
D	> 2.0mm	Classificado pior que C				
E		Não determinado				

Após esta avaliação fica-se assim com a noção da classificação NATO atribuída ao produto final obtido pelo processo proposto.

CAPÍTULO 4

RESULTADOS E DISCUSSÃO

4.1 - CLASSIFICAÇÃO DE IMAGEM

No que diz respeito a esta fase do processo de identificação e extração de objetos relativos ao edificado e rede viária como já foi referido anteriormente é avaliado com o recurso a uma matriz de contingências, desta forma nos próximos subcapítulos irá ser exposto o resultado obtido para cada um dos métodos utilizados.

Na classificação efetuada com os classificadores referidos no subcapítulo 3.3, foram definidas 6 classes: água, asfalto, edificado habitacional, solo nu, sombra e verde.

Os vários coeficientes da referida matriz vão ser utilizados como justificação das escolhas tomadas, dando-se mais ênfase ao algoritmo que produziu melhores resultados.

4.1.1. Classificação de Imagem de Satélite

Para o caso das imagens de satélite, o algoritmo que produziu melhores resultados foi o SVM, com uma precisão global de 93%, e um índice kappa de 0.91 que segundo Landis et al, corresponde a um resultado próximo da concordância total. Na tabela 4.1 é possível verificar os resultados obtidos pelos classificadores.

Tabela 4.1 – Precisão Global e Coeficiente k - Satélite

<i>Algoritmo</i>	<i>Precisão Global</i>	<i>Coeficiente k</i>
<i>AD</i>	81,67%	0,77
<i>MV</i>	91,75%	0,89
<i>SVM</i>	93,06%	0.91

Na tabela 4.2 a matriz de contingências para as 6 classes de ocupação do solo definidas, sendo possível verificar as classes para as quais se obtêm melhores precisões, assim como as classes passíveis de produzirem maior ruído.

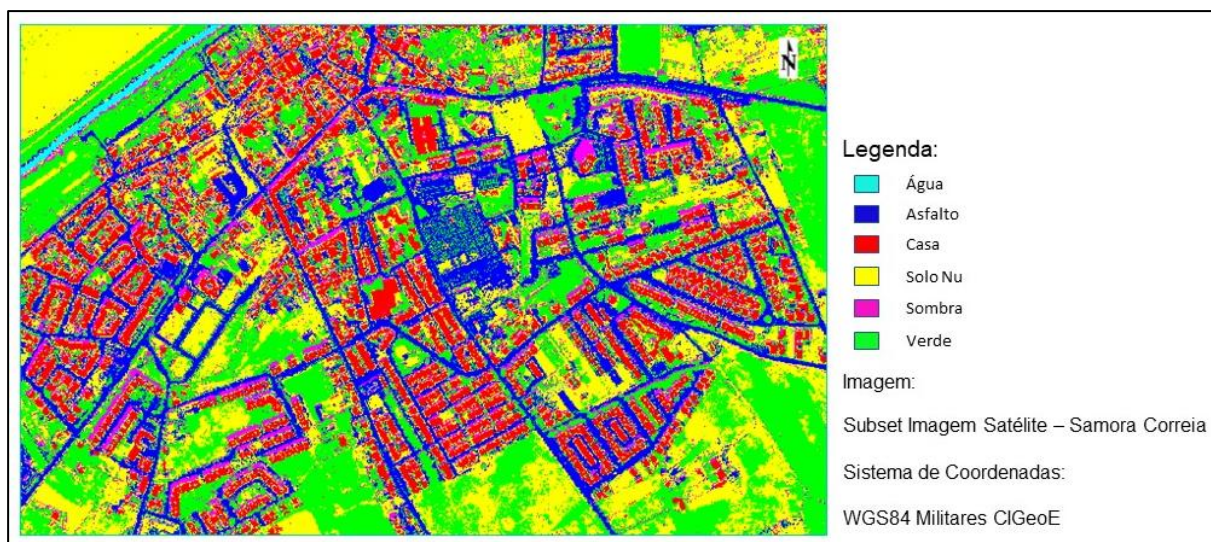
**Figura 4.1** – Classificação SVM-Imagem Satélite

Tabela 4.2 – Tabela de Contingências SVM-Imagem Satélite

<i>Classe</i>	<i>AG</i>	<i>AF</i>	<i>EH</i>	<i>SN</i>	<i>SB</i>	<i>VD</i>	<i>Total</i>	<i>PP (%)</i>	<i>EO (%)</i>
<i>AG</i>	2062	5	70	31	5	0	2173	99,85	0,15
<i>AF</i>	2	25153	27	2929	11	0	28122	97,48	2,52
<i>EH</i>	0	14	12222	89	10	7	12342	88,64	11,36
<i>SN</i>	1	278	1152	22823	21	1232	25507	87,59	12,41
<i>SB</i>	0	18	292	14	5697	278	6299	98,48	1,52
<i>VD</i>	0	334	26	172	41	26741	27314	94,63	5,37
<i>Total</i>	2065	25802	13789	26058	5785	28258	101757		
<i>PU (%)</i>	94,89	89,44	99,03	89,48	90,44	97,9			
<i>EC (%)</i>	5,11	10,56	0,97	10,52	9,56	2,1			

AG – Água EH – Edificado Habitacional SB – Sombra AF – Asfalto SN – Solo Nu VD – Verde
PP – Precisão Produtor EC – Erro Comissão PU – Precisão Utilizador EO – Erro Omissão

Da análise da tabela 4.2 verifica-se que para as classes de objetos a serem extraídas a precisão do produtor é de 97.48% para a classe asfalto e de 88.64% para a classe EH que nos indica a precisão da classificação para as áreas de validação definidas.

Para a classe asfalto embora este algoritmo proporcione um bom resultado geral é produzido algum ruído uma vez que são criados muitos falsos positivos, devendo-se ao facto desta classe abranger alguns objetos com resposta radiométrica semelhante, como é o caso dos objetos da classe EH e solo nu.

A divisão da classe EH em subclasses permitiu chegar a um resultado bastante satisfatório, permitindo uma diminuição do ruído provocado por classes de resposta radiométrica semelhante (solo nu). No caso do classificador MV os resultados são bastante idênticos aos obtidos no SVM, já nas AD o ruído causado foi bastante mais significativo, verificando-se no caso da classe EH que 21.96% das áreas definidas para validação foram atribuídas à classe solo nu, causando um maior número de falsos positivos e por conseguinte um resultado global aquém do desejável.

4.1.2. Classificação da Ortoimagem

No caso da ortoimagem os melhores resultados foram obtidos com AD, tendo-se chegado a uma precisão global de 94.33% e um coeficiente k de 0.927 que à semelhança do obtido na imagem satélite corresponde a uma classificação perto do exato. Na tabela 4.3 é apresentado o resultado obtido com os restantes classificadores, sendo apresentado na figura 4.2 o resultado da classificação obtido com AD.




Figura 4.2 – Classificação AD-Ortoimagem

Tabela 4.3 – Precisão Global e Coeficiente k – Ortoimagem

<i>Algoritmo</i>	<i>Precisão Global</i>	<i>Coeficiente k</i>
<i>AD</i>	94,33%	0,93
<i>MV</i>	93,64%	0,93
<i>SVM</i>	93,57%	0,92

Na ortoimagem ao contrário do que se obteve com a imagem satélite os resultados obtidos pelos vários classificadores são bastante similares, neste caso uma vez que o melhor resultado foi obtido pelo classificador AD, onde a área de estudo é sucessivamente repartida até à total separação dos pixéis, tendo sido para o efeito criadas inúmeras áreas de treino das várias classes, para as quais se efetuam estatísticas.

Desta forma torna-se difícil criar áreas de validação que não estejam abrangidas pelas de treino, levando a querer que os resultados da tabela 4.4 possam estar relacionados com esse facto, apresentando valores demasiado otimistas devido ao processo de ‘overfitting’, no anexo A é apresentada a AD utilizada no processo e no anexo B uma amostra dos vários histogramas utilizados na separação da informação.

Tabela 4.4 – Tabela de Contingências AD-Ortoimagem

<i>Classe</i>	<i>AG</i>	<i>AF</i>	<i>EH</i>	<i>SN</i>	<i>SB</i>	<i>VD</i>	<i>Total</i>	<i>PP (%)</i>	<i>EO (%)</i>
<i>AG</i>	4375	9	0	0	0	0	4384	99,73	0,27
<i>AF</i>	0	19733	49	183	33	136	20134	98,37	1,63
<i>EH</i>	12	176	15411	1868	4	4	17475	92,81	7,19
<i>SN</i>	0	61	815	22426	0	15	23317	86,29	13,71
<i>SB</i>	0	75	299	96	4228	13	4711	88,01	11,99
<i>VD</i>	0	6	31	1417	539	31002	32995	99,46	0,54
<i>Total</i>	4387	20060	16605	25990	4804	31170	103016		
<i>PU (%)</i>	99,79	98,01	88,19	96,18	89,75	93,96			
<i>EC (%)</i>	0,21	1,99	11,81	3,82	10,25	6,04			
AG – Água EH – Edificado Habitacional SB – Sombra AF – Asfalto SN – Solo Nu VD – Verde PP – Precisão Produtor EC – Erro Comissão PU – Precisão Utilizador EO – Erro Omissão									

Para testar a robustez do algoritmo, e de forma a responder a uma das questões derivadas, foi produzida uma nova ortoimagem da zona de Almada correspondente à figura 4.3, e para a qual foram criadas novas áreas de validação, de forma a comprovar os resultados obtidos anteriormente, denominando-se esta de região de validação, ou seja, o classificador foi treinado com dados da ortoimagem de Samora Correia e validado com dados da ortoimagem de Almada.

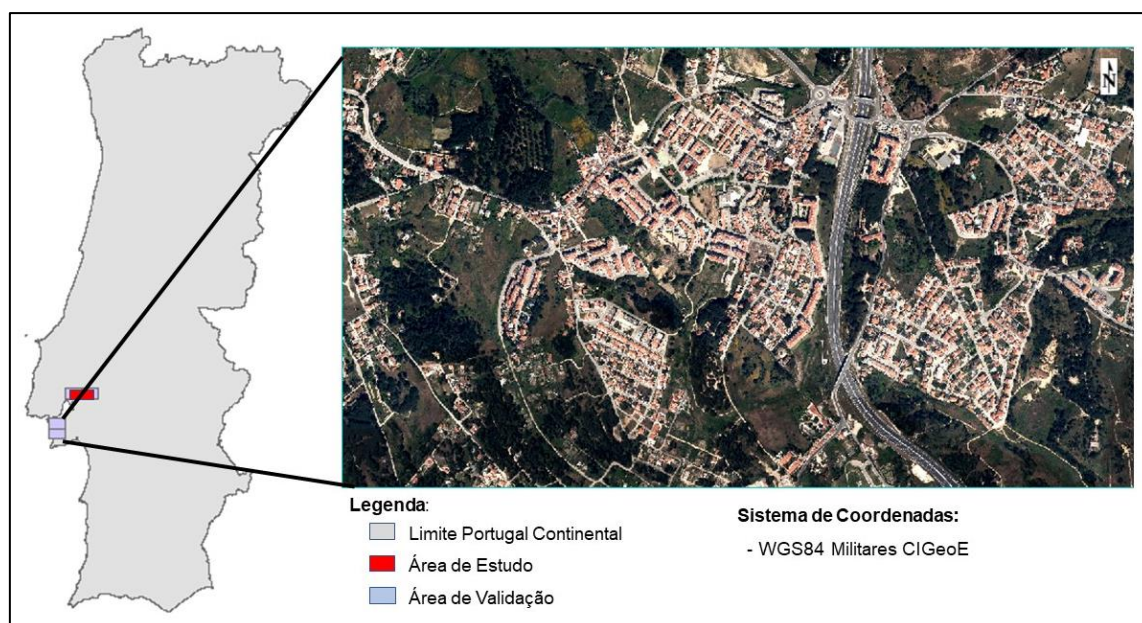


Figura 4.3 – Região de Validação do Algoritmo AD

Para a zona de validação chegou-se a uma precisão global de 92.97% para um coeficiente k de 0.8476, o que comprova a robustez do algoritmo uma vez mesmo numa zona para a qual não foi treinado consegue obter prestações bastante satisfatórias, podendo este ser melhorado consecutivamente à medida que vai sendo aplicado a zonas diferentes.

A tabela 4.5 corresponde à matriz de contingências para a região de validação. Na tabela 4.5 verifica-se a resposta do algoritmo às diferentes classes, verificando-se que o resultado da classe asfalto aparece mais degradado, fruto de uma resposta radiométrica diferente, possivelmente causada pela utilização de outro tipo de cobertura asfáltica (cimento), não existente na região de treino. De referir que a classe água na região de validação não foi avaliada, uma vez que não havia a classe nesta zona.

Verifica-se ainda que a utilização de índices para fins de classificação com AD se mantém estável no espaço. Para um algoritmo que só faz uso da informação radiométrica os resultados são bastante satisfatórios, dando-se como comprovado que os resultados obtidos na área de estudo por este algoritmo se deveram ao estudo exaustivo efetuado, havendo sempre necessidade de reajuste da AD a cada região.

Por este facto optou-se por transitar para a segunda fase do processo de aquisição de informação, além do resultado proveniente das AD, o resultado proveniente do algoritmo MV, uma vez que foi o que obteve o segundo melhor resultado.

Tabela 4.5 – Tabela de Contingências AD-Ortoimagem Validação

Classe	AG	AF	EH	SN	SB	VD	Total	PP (%)	EO (%)
AG	-	-	-	-	-	-	-	-	-
AF	-	11951	38	152	722	68	12931	71,23	28,77
EH	-	345	25612	3116	37	3	29113	90,11	9,89
SN	-	4455	2704	21190	4	48	28401	73,11	26,89
SB	-	0	41	4	5061	0	5106	54,44	45,56
VD	-	26	29	4520	3472	197683	205730	99,94	0,06
Total	-	16777	28424	28982	9296	197802	281281		
PU (%)	-	92,42	87,97	74,61	99,12	96,09			
EC (%)	-	7,58	12,03	25,39	0,88	3,91			
AG – Água EH – Edificado Habitacional SB – Sombra AF – Asfalto SN – Solo Nu VD – Verde									
PP – Precisão Produtor EC – Erro Comissão PU – Precisão Utilizador EO – Erro Omissão									

4.2 - MORFOLOGIA BINÁRIA E FILTRAGEM

A filtragem de imagem e as operações morfológicas possibilitam a eliminação de algum ruído provocado pelos classificadores, contudo embora as mesmas possam ser implementadas através de programas elaborados em código aberto neste caso devido à especificidade de cada output produzido pelo classificador, há a necessidade de alterar a sequência de instruções.

4.2.1. Máscara da Classe Edificado Habitacional (EH)

A máscara binária criada a partir de cada classe além de aparecer bastante “pixelizada” tem inúmeros falsos positivos de dimensões não significativas. Nas figuras 4.4 a 4.6 é possível visualizar o antes e depois da aplicação de operações de filtragem através da aplicação do filtro da média e operadores morfológicos como a erosão e fecho.

Para a classe EH, no geral foi aplicado inicialmente um filtro da média com um kernel 5x5 de forma obter uma imagem mais homogênea, eliminando o ruído proveniente de falsos positivos. Posteriormente realizou-se uma operação de fecho de forma a que pequenos vazios causados por sombras ou objetos com uma resposta radiométrica diferente à dos telhados deixem de aparecer na imagem, tornando o limite do edifício homogêneo.




Figura 4.4 – Imagem Binária da Classe EH SVM-Satélite, a) Classe EH após classificação b) Classe EH após aplicação de operadores morfológicos e de filtragem.




Figura 4.5 – Imagem Binária da Classe EH AD-Orto a) Classe EH após classificação b) Classe EH após aplicação de operadores morfológicos e de filtragem.




Figura 4.6 – Imagem Binária da Classe EH MV-Orto, a) Classe EH após classificação b) Classe EH após aplicação de operadores morfológicos e de filtragem.

Da análise visual das imagens binárias obtidas inicialmente figuras 4.4a, 4.5a e 4.6a, coluna esquerda, verifica-se que os algoritmos de classificação paramétricos, MV e SVM proporcionam melhores resultados que as AD no que respeita ao ruído provocado, uma vez que o resultado antes e após aplicação dos operadores mantém-se praticamente inalterado, estando as delimitações dos edifícios bem definidas.

No que respeita à utilização de imagem satélite, para o classificador escolhido esta origina menos ruído que a proveniente do orto, devido à menor resolução espacial.

4.2.2. Máscara da Classe Asfalto

No que respeita à classe asfalto, a confusão com outros elementos da superfície cuja constituição é à base de alcatrão faz com que exista uma grande probabilidade de ocorrerem falsos positivos. Contudo, nesta fase do processo definiu-se como objetivo a homogeneização da imagem por forma a chegar à melhor aproximação de uma rede de vias.

Para esta classe foram aplicadas além do filtro da média, operações morfológicas de erosão e dilatação tendo sido utilizado um kernel 3x3 ou 5x5 consoante o ruído inicial, tendo-se executado o processo de forma iterativa até à obtenção do melhor resultado.

Nas figuras 4.7 a 4.9 é apresentado o resultado da classe asfalto para cada classificador utilizado.

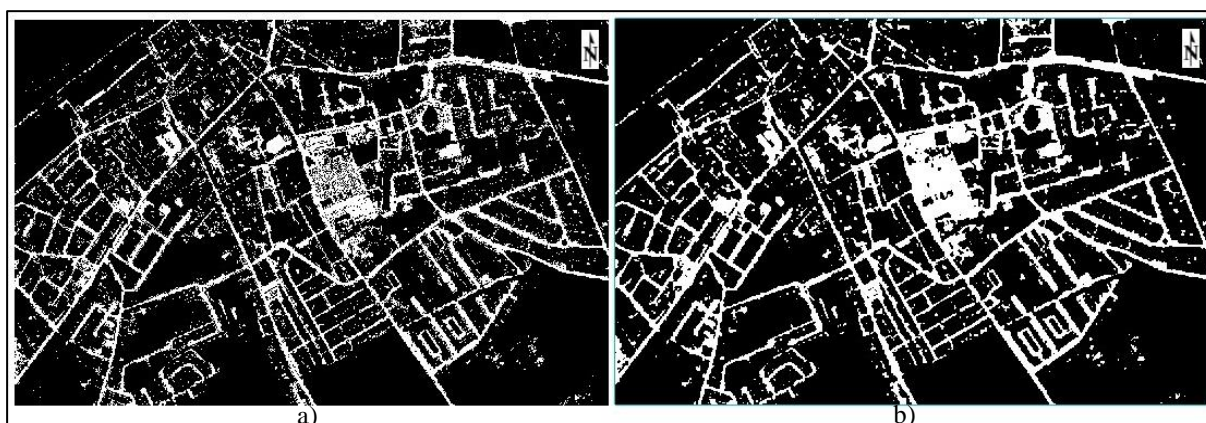


Figura 4.7 – Imagem Binária da Classe asfalto SVM-Satélite, a) Classe asfalto após classificação b) Classe asfalto após aplicação de operadores morfológicos e de filtragem




Figura 4.8 – Imagem Binária da Classe asfalto AD-Ortoimagem, a) Classe asfalto após classificação b) Classe asfalto após aplicação de operadores morfológicos e de filtragem




Figura 4.9 – Imagem Binária da Classe asfalto MV-Ortoimagem, a) Classe asfalto após classificação b) Classe asfalto após aplicação de operadores morfológicos e de filtragem

À semelhança da classe EH o SVM e MV proporcionam um menor nível de ruído, contudo após a aplicação dos operadores morfológicos e de filtragem ao resultado da classificação por AD, obtém-se um resultado semelhante, sendo o restante processo de filtragem efetuado em ArcGis, onde elementos como parques de estacionamento e alguns falsos positivos vão ser eliminados manualmente.

As máscaras geradas por cada objeto evidenciaram um dos principais constrangimentos à classificação de imagem para fins cartográficos é a existência de sombras uma vez que cria lacunas nos objetos dificultando a delimitação do mesmo e respetiva extração de forma automática.

4.2 - GENERALIZAÇÃO DA INFORMAÇÃO ADQUIRIDA

Neste projeto o objetivo da generalização é a preparação de informação para representação final, de modo que a informação adquirida através de classificadores possa ser equiparada com a adquirida manualmente por operadores de fotogrametria, uma vez que quando se efetua a passagem de *raster* para vetor os polígonos criados vêm extremamente pixelizados como já foi referido anteriormente, sendo o principal objetivo desta fase a regularização da informação adquirida.

4.3.1. Generalização da Classe Edificado Habitacional

Para a classe EH o objetivo será chegar a uma representação do objeto o mais simplificada possível, isto é, que o objeto seja representado com o menor número de vértices sem comprometer a sua forma geométrica.

Uma vez que no terreno existem zonas onde a construção se processou de forma ordenada e outras onde por falta de ordenamento ou outras razões a mesma resultou em aglomerados de edifícios irregularmente distribuídas no espaço, há a necessidade de estabelecer dois tipos de generalização distinta para cada uma destas zonas.

Desta forma foi definido um modelo genérico representado na figura 4.10, que engloba todo o processo de generalização, onde constam todas as ferramentas necessárias para o efeito. Assim sendo a primeira ferramenta a ser aplicada é a de agregação de polígonos, onde é definido o limiar a partir do qual a agregação é feita e o limite mínimo de áreas a representar. Nesta ferramenta para a classe EH foi ainda definida uma barreira, através criação de uma *shapefile* com o resultado final da classificação da classe

asfalto para que o processo de generalização não deforme os objetos. A aplicação desta ferramenta não respeita as normas de aquisição impostas pelo CIGeoE, uma vez que a área mínima a representar é de 50m^2 e não de 9m^2 como as normas o impõem, assim como os pátios interiores onde as normas definem como área mínima a adquirir 100m^2 e aqui foi definida uma área extremamente superior para que os falsos positivos e irregularidades provenientes da classificação pudessem ser minimizadas.

Após a agregação inicial aplica-se o regularizador da pegada do edifício, tornando os contornos em segmentos de reta, após este efetua-se novamente uma agregação pelo facto da ferramenta anterior poder separar alguns dos edifícios inicialmente agregados. Por fim efetua-se uma simplificação do edifício de forma a que a pegada do edifício seja o mais aproximado de um polígono regular.

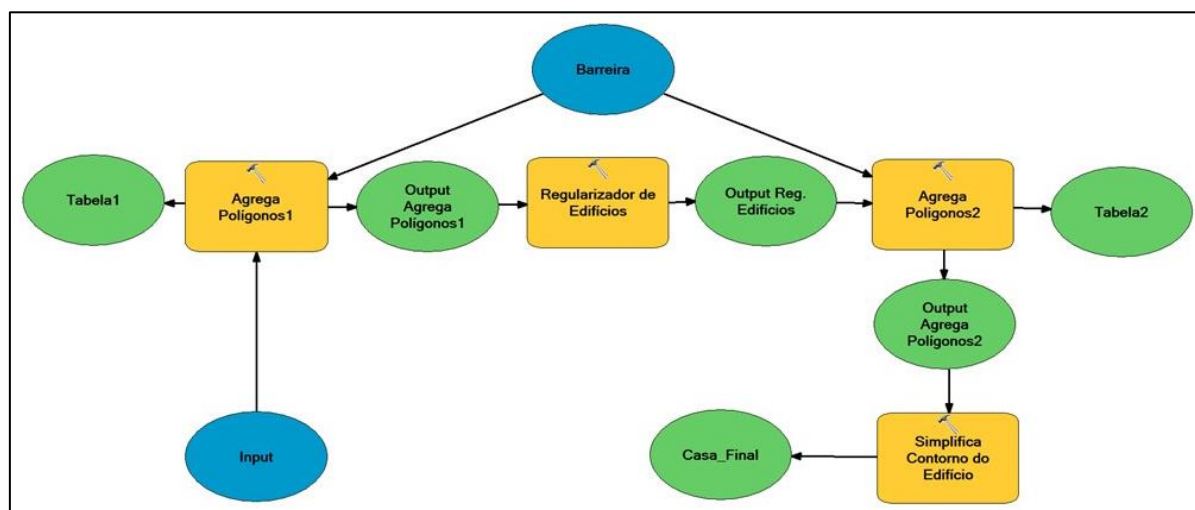


Figura 4.10 – Modelo de Generalização Classe EH

Uma vez que se tem áreas com características diferentes, o modelo terá de ser adaptado a cada uma dessas zonas, por uma adaptação dos parâmetros das ferramentas utilizadas, sendo gerados dois outputs relativos à mesma classe (regular/irregular), desta forma nos próximos subcapítulos será efetuada a exposição dos resultados obtidos para cada uma dessas áreas, aplicado ao algoritmo AD e MV no caso da ortoimagem e SVM para a imagem de satélite.

Para cada área será efetuada uma estatística comparativa seguindo a metodologia proposta anteriormente, com os dados existentes à data, adquiridos manualmente por operadores fotogramétricos.

4.3.1.1. Classe Edificado Habitacional Irregular

A zona Noroeste da área de estudo, correspondente à zona antiga da região de Samora Correia foi definida como sendo a área onde a construção se encontra irregularmente distribuída, tendo sido aplicados os parâmetros de generalização para este tipo de áreas. Na figura 4.11 a 4.13 é apresentado o resultado final dos algoritmos aplicados às duas imagens antes e depois da generalização.



Figura 4.11 – Generalização EH Irregular AD – Orto, a) Classe EH após filtragem b) Classe EH após generalização



Figura 4.12 – Generalização EH Irregular MV – Orto, a) Classe EH após filtragem b) Classe EH após generalização



Figura 4.13 – Generalização EH Irregular SVM – Satélite, a) Classe EH após filtragem b) Classe EH após generalização

Após o processo de generalização torna-se necessário avaliar o resultado obtido no que respeita à forma como o objeto se encontra representado no terreno e se está em concordância com a referência (cartografia CIGeoE). Para o efeito, a fim de aplicar a metodologia anteriormente exposta, foi definida a amostra de edifícios irregulares ilustrada na figura 4.14, definida por 20 edifícios dos 135 existentes, correspondendo a uma área coberta de 31143.61m², sendo esta amostra tomada como referência para análises posteriores.

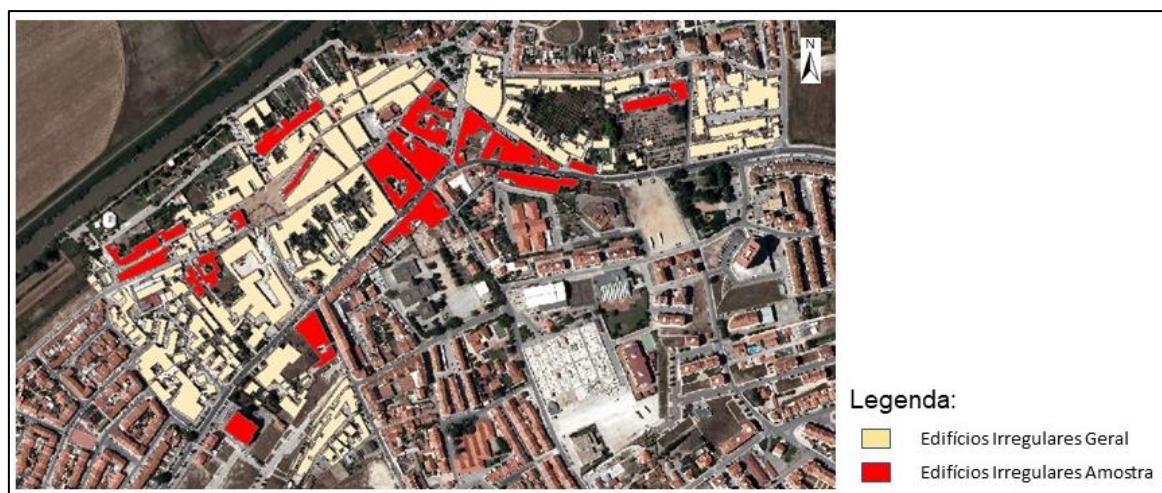


Figura 4.14 – Amostra EH Irregular

Na tabela 4.6 é apresentado o resultado da avaliação efetuada, da análise da mesma verificamos que o algoritmo AD foi o que proporcionou melhores resultados, uma vez que no que respeita a área coberta foi o que se aproximou mais da referência.

No que respeita à geometria, onde é avaliada a orientação espacial do objeto em relação à verdade do terreno e à referência, todos os algoritmos obtiveram o mesmo resultado, uma vez que para a zona irregular foram criados alguns falsos positivos, de referir ainda que de todos os algoritmos em estudo o que requereu mais edição foi o da MV, sendo que para o SVM e AD foram poucos os casos onde tal ocorreu.

Tabela 4.6 – Avaliação Nível II - EH Irregular

<i>Algoritmo</i>	<i>SVM (satélite)</i>	<i>AD (orto)</i>	<i>MV (orto)</i>
<i>Nº de polígonos classificados para definir referência</i>	1,42	1,74	1,21
<i>Diferença de área coberta (%), para uma área total validada de 31143.61m²</i>	-40,53%	-10,11%	-19,03%
<i>Geometria</i>	2,00	1,74	1,79

4.3.1.2. Classe Edificado Habitacional Regular

No que respeita à subclasse EH regular, os algoritmos de generalização proporcionaram excelentes resultados, tendo inclusive adquirido áreas não restituídas anteriormente, resultado de processos de construção recentes, no que respeita a comportamento dos vários algoritmos, verificou-se que ambos proporcionam bons resultados gerais.

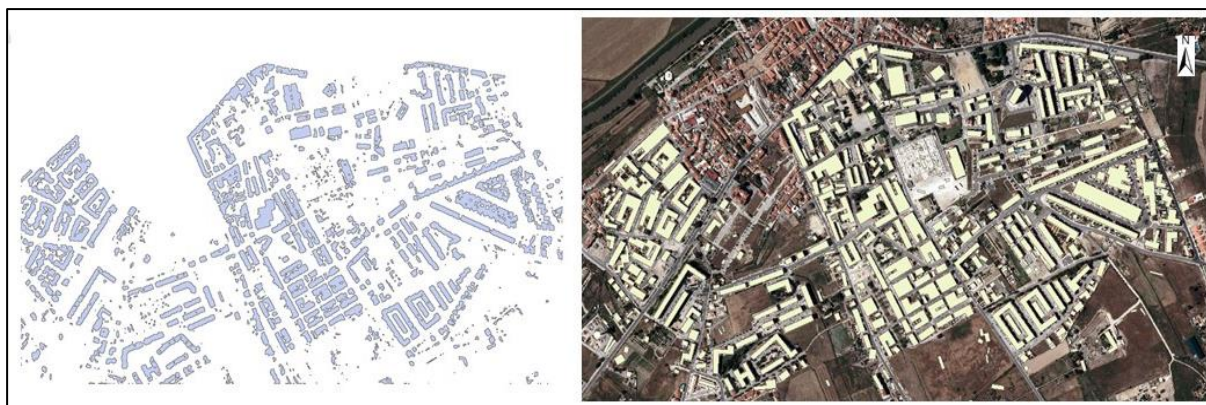


Figura 4.15 – Generalização EH Regular AD – Orto




Figura 4.16 – Generalização EH Regular MV – Orto

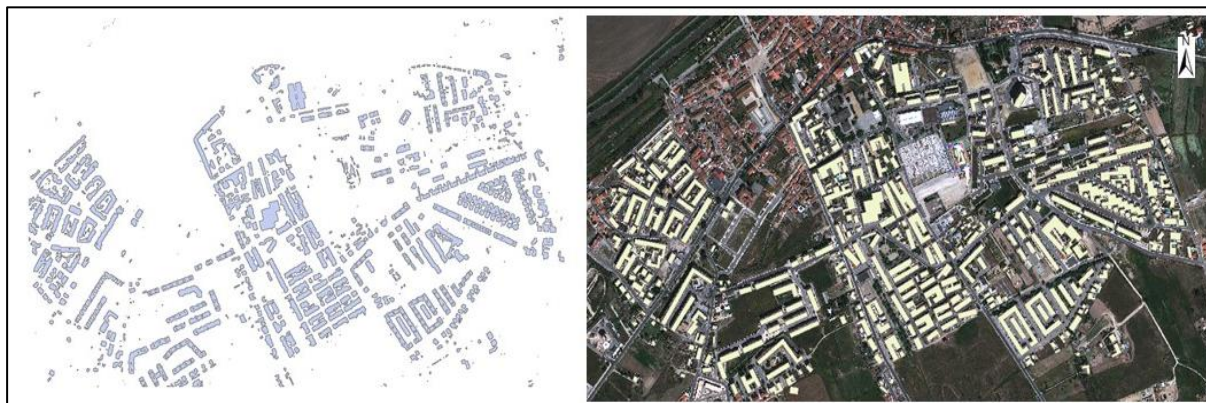


Figura 4.17 – Generalização EH Regular SVM – Satélite

Na avaliação de nível II a esta subclasse, à semelhança da anterior, foi efetuada por comparação com uma amostra aleatória de 48 casas referência, correspondendo a uma área total de edificado de 65694.94m², visível na figura 4.18.

A tabela 4.7 resume os resultados da avaliação nível II para esta subclasse, onde se verifica uma maior compatibilidade com a informação de referência, uma vez que a área coberta assume valores positivos, devendo-se este facto a uma maior generalização do objeto, uma vez que as normas de aquisição sofreram uma adaptação ao caso estudo, não tendo sido adquiridos pátios interiores até 100m² como

estas o exigem, nem adquiridas casas com uma área de implantação de $9m^2$, pois iria gerar um maior número de falsos positivos.

Tabela 4.7 – Avaliação Nível II – EH Regular (m)

Algoritmo	SVM (satélite)	AD (orto)	MV (orto)
Nº De Polígonos Classificados para definir referência	1,32	1,05	0,97
Diferença de área coberta (%) para uma área de validação de $65694.94m^2$	-18,75%	+21,93	+4,00%
Geometria	1,32	1,16	1,42




Figura 4.18 – Amostra EH Regular

No respeito à geometria os elementos adquiridos por qualquer um dos classificadores foi generalizado em média conforme se encontra no terreno, não havendo necessidade de edição. Contudo, foram identificados alguns casos onde houve uma rotação do objeto após generalização, sendo esses casos identificados como geometria incorreta, item que em média assumiu valor (1).

Para este tipo de objeto foi ainda efetuada uma análise mais aprofundada à geometria do mesmo, através da implementação do processo proposto no capítulo anterior para esta temática, onde através da passagem dos objetos de polígonos para pontos foi assumido que uma diferença inferior a 0.8m (valor determinado empiricamente através da observação da intersecção com o ficheiro referência) entre o ficheiro classificado e a referência correspondia a pontos que definiam o mesmo objeto no espaço, tendo-se utilizado esta informação para efetuar uma análise à geometria dos objetos, a tabela 4.8 resume a avaliação efetuada.

Tabela 4.8 – Avaliação Nível II - EH Regular Geometria (m)

		Erro em M	Erro em P	Vetor Desvio
<i>AD</i>	Média	-0,020	-0,095	0,097
	Desvio Padrão	0,398	0,396	0,561
<i>MV</i>	Média	-0,148	0,056	0,578
	Desvio Padrão	0,428	0,383	0,199
<i>SVM</i>	Média	0,133	-0,008	0,133
	Desvio Padrão	0,347	0,380	0,515

Da análise da tabela 4.8 pode verificar-se que o desvio entre o ficheiro classificado e a referência é inferior a 0.5m, isto é, obteve-se um erro inferior à resolução espacial da imagem utilizada.

Sendo que o erro observado se deve à forma como o algoritmo de classificação processou os dados, e o facto de que em muitos casos o mesmo telhado gera uma resposta radiométrica diferente, o que pode justificar os erros determinados, uma vez que basta o algoritmo não reconhecer uma parte do telhado para que o polígono gerado seja diferente, alterando desta forma a geometria do mesmo.

4.3.2. Generalização da Classe Asfalto

No que reporta à generalização da classe asfalto à semelhança da classe EH foi desenvolvido um modelo apresentado na figura 4.19 para aplicação das ferramentas atrás apresentadas de forma automática. Desta forma foram determinados parâmetros que proporcionassem os melhores resultados gerais. Inicialmente uma vez que toda a informação desta camada se encontrava sob a forma de polígono foram aplicadas as ferramentas de agregação e simplificação, de forma a suavizar o aspeto dos polígonos resultantes da classificação.

Neste processo ao contrário do anterior existe uma fase de edição manual, de forma a eliminar parques de estacionamento e falsos positivos, que devido à sua configuração geométrica não são compatíveis com a classe asfalto, onde se pretende obter elementos lineares.

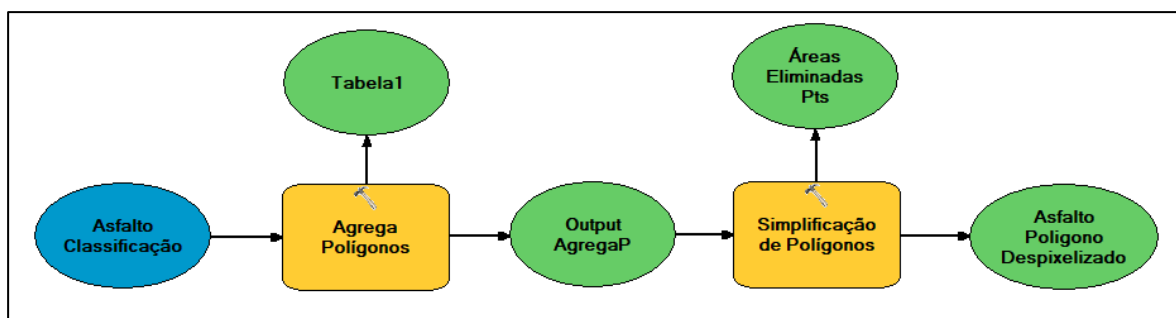


Figura 4.19 – Modelo de Simplificação da Classe Asfalto

Após a eliminação dos principais falsos positivos manualmente passa-se á conversão de polígonos para linhas, onde se obtiveram os resultados apresentados da figura 4.20 à figura 4.22, resultado da aplicação da ferramenta apresentada no ponto (3.3.4.2) a), *polygon to central line*.



Figura 4.20 – Resultado de Passagem para Linha Central AD - Orto



Figura 4.21 – Resultado de Passagem para Linha Central MV – Orto



Figura 4.22 – Resultado de Passagem para Linha Central SVM – Satélite

Nesta fase o algoritmo que proporcionou piores resultados foi o da MV (ortoimagem), o SVM foi o que visualmente proporcionou melhores resultados, contudo o processo de edição manual para este algoritmo foi bastante moroso uma vez que este gerou um maior número de erros. As AD nesta fase foi o algoritmo que proporcionou uma melhor relação quantidade/qualidade de informação adquirida, uma vez que o tempo despendido para correção de erros foi mínimo.

Após a determinação da linha central passou-se para a fase de generalização final para a classe asfalto onde se obtiveram os resultados apresentados na figura 4.23 e 4.24, relativos ao processo que proporcionou melhores resultados na fase anterior para cada um dos inputs (ortoimagem/imagem satélite).



Figura 4.23 – Resultado Final Classe Asfalto AD



Figura 4.24 – Resultado Final Classe Asfalto SVM

A avaliação desta classe procedeu-se num só nível conforme indicado no capítulo anterior, tendo-se chegado aos resultados estatísticos apresentados na tabela 4.9.

Tabela 4.9 – Avaliação da Classe Asfalto

		Erro em M	Erro em P	Vetor Desvio	Total de Metros Adquiridos Classificação	Total de Metros Adquiridos Referência
AD	Média	0,091	-0,051	1,528	19561,690	35629,14
	Desvio Padrão	1,309	1,511	0,997		
SVM	Média	-0,105	-0,181	1,630	22914,030	40375,22
	Desvio Padrão	1,417	1,521	1,015		

Da avaliação da tabela (4.9), verifica-se que a classificação por AD proporcionou melhores resultados embora no que respeita a via adquirida fique aquém do classificador SVM, contudo embora a diferença entre aproximações ao eixo de via referência seja mínima, o resultado obtido através de AD proporciona melhores resultados gerais.

4.3.3. Avaliação Final

No final de todo o processo proposto é necessário efetuar um controlo de qualidade à informação adquirida, de forma a que à mesma seja atribuída uma classificação respeitante à exatidão posicional, ajudando a compreender a viabilidade de aplicação deste tipo de processos de aquisição numa cadeia de produção cartográfica como a do CIGeoE.

Desta feita recorrendo a métodos oficiais utilizados para efeitos de controlo de qualidade foi aplicada a avaliação nível III referida anteriormente, onde é calculado o valor de CMAS que nos transmite o grau de exatidão posicional.

Este método embora tenha resultado de uma adaptação do que é feito oficialmente, traduz de certa forma um valor que nos permite visualizar a escala a que o conjunto de dados adquiridos é mais facilmente aceite correspondendo à escala para a qual o valor de CMAS calculado corresponde ao melhor resultado classificativo, que de acordo com a tabela 3.7 corresponde a “A”.

Assim sendo após o cálculo do valor de CMAS para o conjunto de dados adquiridos via ortoimagem e imagem satélite com os algoritmos AD e SVM respetivamente chegou-se aos resultados apresentados na tabela 4.10.

Tabela 4.10 – Avaliação CMAS

<i>CMAS (m)</i>		<i>Classificação</i> <i>1:25000</i>
<i>Ortoimagem (AD)</i>	0.87	A
<i>Imagem Sat. (SVM)</i>	0.81	A

Da análise da tabela 4.10 pode concluir-se que a informação adquirida pode ser implementada em qualquer tipo de escalas, uma vez que lhe é atribuída a classificação ‘A’ para a escala 1:25000, escala que exige uma maior precisão.

Contudo como já foi referido, o estudo efetuado faz uma “abordagem” ao controlo de qualidade segundo as normas definidas pelo STANAG 2215, sofrendo algumas adaptações, tais como o facto de não se ter efetuado um levantamento objetivo com GNSS à área de trabalhos, tendo sido tomado como referência os dados disponibilizados pelo CIGeoE (informação vetorial das cartas da área em estudo), que por serem dados adquiridos via restituição fotogramétrica têm erros associados, estes podem ter levado a uma degradação do resultado final ou pelo contrario ter chegado a uma solução demasiado otimista.

No que respeita à imagem de satélite o facto de se ter adotado o sistema de coordenadas WGS84 Militares do CIGeoE, levou a que houvesse necessidade de efetuar uma transformação de coordenadas, que por não se dispor de parâmetros de transformação entre o sistema de coordenadas que a imagem satélite se encontrava optou-se por efetuar uma georreferenciação da mesma com os PF’s levantados através de GNSS, podendo este ser vistos como um dos fatores influenciadores de erro.

CAPÍTULO 5

CONCLUSÕES E PERSPETIVAS FUTURAS

5.1 - PRINCIPAIS CONCLUSÕES

Inicialmente foram definidas questões que serviram como guia do estudo efetuado, procurando resposta para as mesmas através da aplicação das metodologias adotadas em todo o projeto. Neste capítulo, são respondidas às 4 questões colocadas inicialmente e elaboradas as principais conclusões do trabalho de projeto.

No que se refere à questão principal:

“A classificação de imagens multiespectrais terá a precisão suficiente para dar resposta às necessidades da cadeia de produção cartográfica do CIGeoE?”

Numa grande empresa quando se tem uma cadeia de produção bem montada e com provas dadas a nível de qualidade do produto final obtido, um processo de mudança é sinónimo de custos acrescidos, que embora possam ter retorno a longo prazo, tal mudança terá de ser escrupulosamente justificada.

O CIGeoE é uma unidade do Exército Português reconhecida pela qualidade do seu trabalho e pelo detalhe com que o seu principal produto é elaborado, fruto de um catálogo de objetos bastante completo.

No presente trabalho propusemo-nos estudar a aquisição de informação e efetuar a comparação da mesma com o produto final da fotogrametria, logo se o objetivo for obter de forma automática o mesmo nível de detalhe de um operador fotogramétrico e adquirir por completo todos os objetos constantes nas normas de aquisição a resposta à primeira questão é não, uma vez que após a determinação de todos os parâmetros de generalização se chegou à conclusão que os limites mínimos de aquisição não conseguem ser cumpridos, uma vez que respeitar os mesmos irá levar a uma degradação do resultado final gerando um grande número de falsos positivos.

O facto de se adquirir informação apenas em 2d também é visto como outra desvantagem relativamente ao processo via restituição fotogramétrica, uma vez que através do processo proposto não conseguimos obter informação altimétrica, não sendo assim possível gerar as curvas de nível, essenciais à cartografia produzida no CIGeoE.

Contudo se pretendermos obter informação para as classes de objetos estudadas apenas a pensar na representação 1:25000, a resposta à questão inicial é sim com algumas limitações, uma vez que embora a nível de exatidão posicional segundo a tabela 4.10 se obtém classificação A, as normas atuais têm de ser revistas uma vez que para efetuar classificação segundo estas regras será gerado um grande volume de ruído.

No que respeita à classe EH este pode ser um processo viável, sendo que a sua melhor aplicação deverá passar por fazer uso do processo proposto para aquisição adicional de informação a dar ao operador fotogramétrico de forma a rentabilizar trabalho, sendo que o input a dar ao sistema teria de ser a ortoimagem, de forma a rentabilizar o custo de produção.

No caso do objeto asfalto a classificação de acordo com as normas de aquisição não deverá trazer vantagens uma vez que o mesmo objeto, isto é, um objeto cuja resposta radiométrica é a mesma tem uma classificação diferente (ao asfalto corresponde, estrada larga, estrada estreita, arruamento e acesso auto), tendo de haver trabalho manual na atribuição correta do designador do objeto, pelo que não deverá trazer vantagens à cadeia de produção.

Questões derivadas:

“Os resultados obtidos justificam uma mudança da forma de operar da cadeia de produção?”

“No que respeita a custos de produção, será uma mais valia a aquisição de informação por classificação?”

“As árvores de decisão poderão ser adotadas universalmente para classificação de imagens provenientes do mesmo sensor?”

A nível das questões derivadas, algumas já foram respondidas direta ou indiretamente, sendo que para a questão relativa à aplicação universal das AD embora os resultados obtidos no processo de avaliação tenham sido bastante positivos, para dar uma resposta com maior grau de certeza este processo teria de ser aplicado a outras regiões, com vista a verificar a estabilidade do mesmo e aí poder afirmar, que é possível aplicar AD sem recorrer a novas regiões de treino.

A nível de custos de produção se o processo for aplicado com vista a prover o operador com informação adicional, o mesmo poderá gerar retorno uma vez que poderá otimizar o tempo de restituição, no entanto terá de ser equacionado o rácio tempo ganho/despendido com a correção de erros, sendo que esse processo deveria ser realizado com ortomagens, uma vez que as imagens satélite têm um custo associado bastante elevado, sendo que a sua compra só seria justificada se fosse possível obter resultados idênticos aos atuais via restituição fotogramétrica (possibilidade de adquirir todos os elementos constantes nas normas de aquisição do CIGeoE), neste projeto concluiu-se que para adquirir objetos da classe EH as normas teriam de ser alteradas por forma a que o algoritmo implementado gerasse menos falsos positivos.

No que se refere à comparação de elementos adquiridos com as diferentes imagens (orto e satélite), as diferenças não são significativas podendo afirmar que o resultado que se obtém é idêntico, sendo que a utilização de AD em imagens de satélite com quatro bandas torna-se bastante limitativo, uma vez que não permite uma discretização detalhada do terreno. No caso da ortoimagem esta permitiu uma elevada discretização sendo as AD o algoritmo de referência para este tipo de dados de entrada.

Para a imagem satélite determinou-se o SVM como algoritmo de referência, contudo este requer uma grande capacidade computacional, uma vez que para uma área de estudo de dimensão reduzida revelou-se bastante moroso. No que se refere ao investimento em imagens deste tipo, atualmente o mesmo de acordo com o estudo efetuado neste projeto, não traz mais valias, uma vez que para garantir a qualidade do produto produzido pelo CIGeoE o processo de restituição fotogramétrica é essencial.

Conclui-se então que para projetos em que o nível de dados de treino e o tempo para a disponibilização de produtos seja reduzido, este tipo de processamento revela-se eficaz uma vez se obtêm bons resultados classificativos e são gerados dados vetoriais num curto intervalo de tempo, tendo como principal

limitação ao processo de classificação as sombras produzidas por alguns objetos constantes na imagem, responsáveis por grande parte do ruído produzido pelo classificador, assim como o facto de que algumas regras estabelecidas nas normas de aquisição não são cumpridas.

5.2 - POTENCIAIS UTILIZAÇÕES DO PROCESSO

Para além de projetos de cartografia topográfica esta é uma temática que permite um vasto leque de aplicações, entre as quais se destacam a análise de densidade populacional, análise de fenómenos naturais (cheias, incêndios entre outros) e um vasto leque de aplicações de monitorização de coberto vegetal assim como apoio a operações militares de emergência e projeção de força para zonas sem topografia de base.

No caso das aplicações militares, o uso da deteção remota para obtenção de informação geoespacial em operações é uma área para a qual se deve dar especial atenção pois, com toda a informação disponibilizada nos dias de hoje podem ser realizados estudos prévios do terreno na fase de planeamento e durante a operação, com imagens multiespectrais obtidas via satélite, *drones* e imagens SAR (*Synthetic Aperture Radar*), onde os dados SAR se revestem de especial importância pelo facto destes serem independentes das condições atmosféricas e do meio onde muitas operações se desenrolam.

Cada vez mais o tema do *geointelligence* é explorado sendo visto pela área militar como uma ferramenta crucial em operações, uma vez que através da análise de correlação de vários dados georreferenciados é possível saber mais sobre localização de possíveis alvos, delimitação de zonas de interesse estratégico assim como monitorização da atividade de infraestruturas de insurgentes entre outras.

A deteção remota através de técnicas de classificação temática tem assim a possibilidade de ser inserida em muitas destas tarefas, por deteção de alterações através da análise de séries temporais, classificação de imagens para fins de estatística demográfica (determinar número aproximado de habitantes numa área urbana), sendo uma ferramenta que possibilita adquirir dados de forma automática e gerar cartografia para escalas menores (inferior a 1:25000) com uma exatidão posicional correspondente a A segundo o STANAG 2215, sendo uma escala suficiente para o planeamento de missões.

5.3 - PERSPETIVAS FUTURAS

No que se refere a perspetivas futuras este tipo de processamento poderá ser alvo de melhorias, com a introdução de algoritmos de *machine learning*, assim como uma avaliação mais profunda à utilização desta metodologia na cadeia de produção do CIGeoE, verificando se a mesma se reveste de uma mais valia, onde tal só pode ser validado se for contabilizado o tempo e investimento monetário com cada um dos processos aplicados à mesma área de trabalhos.

O alargamento da zona de testes da AD também pode ser visto como um dos trabalhos a realizar futuramente, com vista à diminuição do ‘*overfitting*’, aumentando o número de áreas de treino.

Contudo este tipo de processamento embora produza bons resultados a nível de classificação para que se adote uma nova metodologia de aquisição de informação, deverá ser explorada a área do reconhecimento de objetos via DR uma vez que nesta área existem algoritmos mais robustos com capacidade de reconhecer um maior número de objetos do catálogo do CIGeoE.

REFERÊNCIAS BIBLIOGRÁFICAS

- Awad M., Khanna R. (2015) Support Vector Machines for Classification. In: Efficient Learning Machines. Apress, Berkeley, CA
- Ben-Hur, A., Horn, D., Siegelmann, H. T., & Vapnik, V. (2001). Support vector clustering. *Journal of machine learning research*, 2(Dec), 125-137.
- Catalão, J., (2018). Apontamentos da Cadeira Detecção Remota Multiespectral, Faculdade de Ciências da Universidade de Lisboa.
- Drobnjak, S. M., & Božić, B. S. (2018). Evaluation of positional accuracy of digital topographic maps at scale 1: 25 000 (DTM25) on the basis of STANAG 2215 standard. *Vojnotehnički glasnik*, 66(1), 106-121.
- Friedl, M. A., & Brodley, C. E. (1997). Decision tree classification of land cover from remotely sensed data. *Remote sensing of environment*, 61(3), 399-409.
- Gribov A. (2018) Searching for a Compressed Polyline with a Minimum Number of Vertices (Discrete Solution). In: Fornés A., Lamiroy B. (eds) *Graphics Recognition. Current Trends and Evolutions. GREC 2017. Lecture Notes in Computer Science*, vol 11009. Springer, Cham
- Gu, Y., Wang, Q., Jia, X., & Benediktsson, J. A. (2015). A novel MKL model of integrating LiDAR data and MSI for urban area classification. *IEEE transactions on geoscience and remote sensing*, 53(10), 5312-5326.
- Kang, J., Körner, M., Wang, Y., Taubenböck, H., & Zhu, X. X. (2018). Building instance classification using street view images. *ISPRS Journal of Photogrammetry and Remote Sensing*.
- Landis, J., & Koch, G. (1977). The Measurement of Observer Agreement for Categorical Data. *Biometrics*, 33(1), 159-174. doi:10.2307/2529310
- Liasis, G., & Stavrou, S. (2016). Building extraction in satellite images using active contours and colour features. *International Journal of Remote Sensing*, 37(5), 1127-1153.
- Mira, N. (2008). Controlo de Qualidade da Cartografia do Bloco de Lisboa produzida no Instituto Geográfico do Exército. *Boletim do IGeoE*, N.º70, 32-41.
- Navarro, A, (2018). Apontamentos da Cadeira Detecção Remota Multiespectral - Práticas, Faculdade de Ciências da Universidade de Lisboa.
- Neto, P. (2010). Programação II, Notas das Teóricas, Faculdade de Ciências da Universidade de Lisboa.
- Petria, (2015). Object oriented classification - a comparative study of two envi feature extraction methods. Faculty of Hydrotechnical Engineering, Geodesy and Environmental Engineering, Department of Civil Engineering.
- Running, S. W., Loveland, T. R., Pierce, L. L., Nemani, R. R., & Hunt Jr, E. R. (1995). A remote sensing based vegetation classification logic for global land cover analysis. *Remote sensing of Environment*, 51(1), 39-48.

Shea, K. S., & McMaster, R. B. (1989). Cartographic generalization in a digital environment: When and how to generalize. In Proceedings Auto-Carto 9.

Welch, R. (1985). Cartographic potential of SPOT image data. Photogrammetric Engineering and Remote Sensing(ISSN 0099-1112), 51, 1085-1091.

Yu, S., Jia, S., & Xu, C. (2017). Convolutional neural networks for hyperspectral image classification. Neurocomputing, 219, 88-98

Zhou, X., Jancso, T., Chen, C., & Verone, M. W. (2012, March). Urban land cover mapping based on object oriented classification using WorldView 2 satellite remote sensing images. In International Scientific Conference on Sustainable Development & Ecological Footprint (pp. 26-27).

Páginas da Internet Consultadas:

http://www.geosystems.cc/catalogos/DG_GeoEye1_DS.pdf (visitado em 09/23/14JUN2019)

<https://www.harrisgeospatial.com/docs/ISODATAClassification.html> (Consultado em 24/16/11JUN2019)

https://earthobservatory.nasa.gov/features/MeasuringVegetation/measuring_vegetation_2.php (consultado a 25/14/37JUN2019)

<https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47> (Consultado em 26/09/08JUN19)

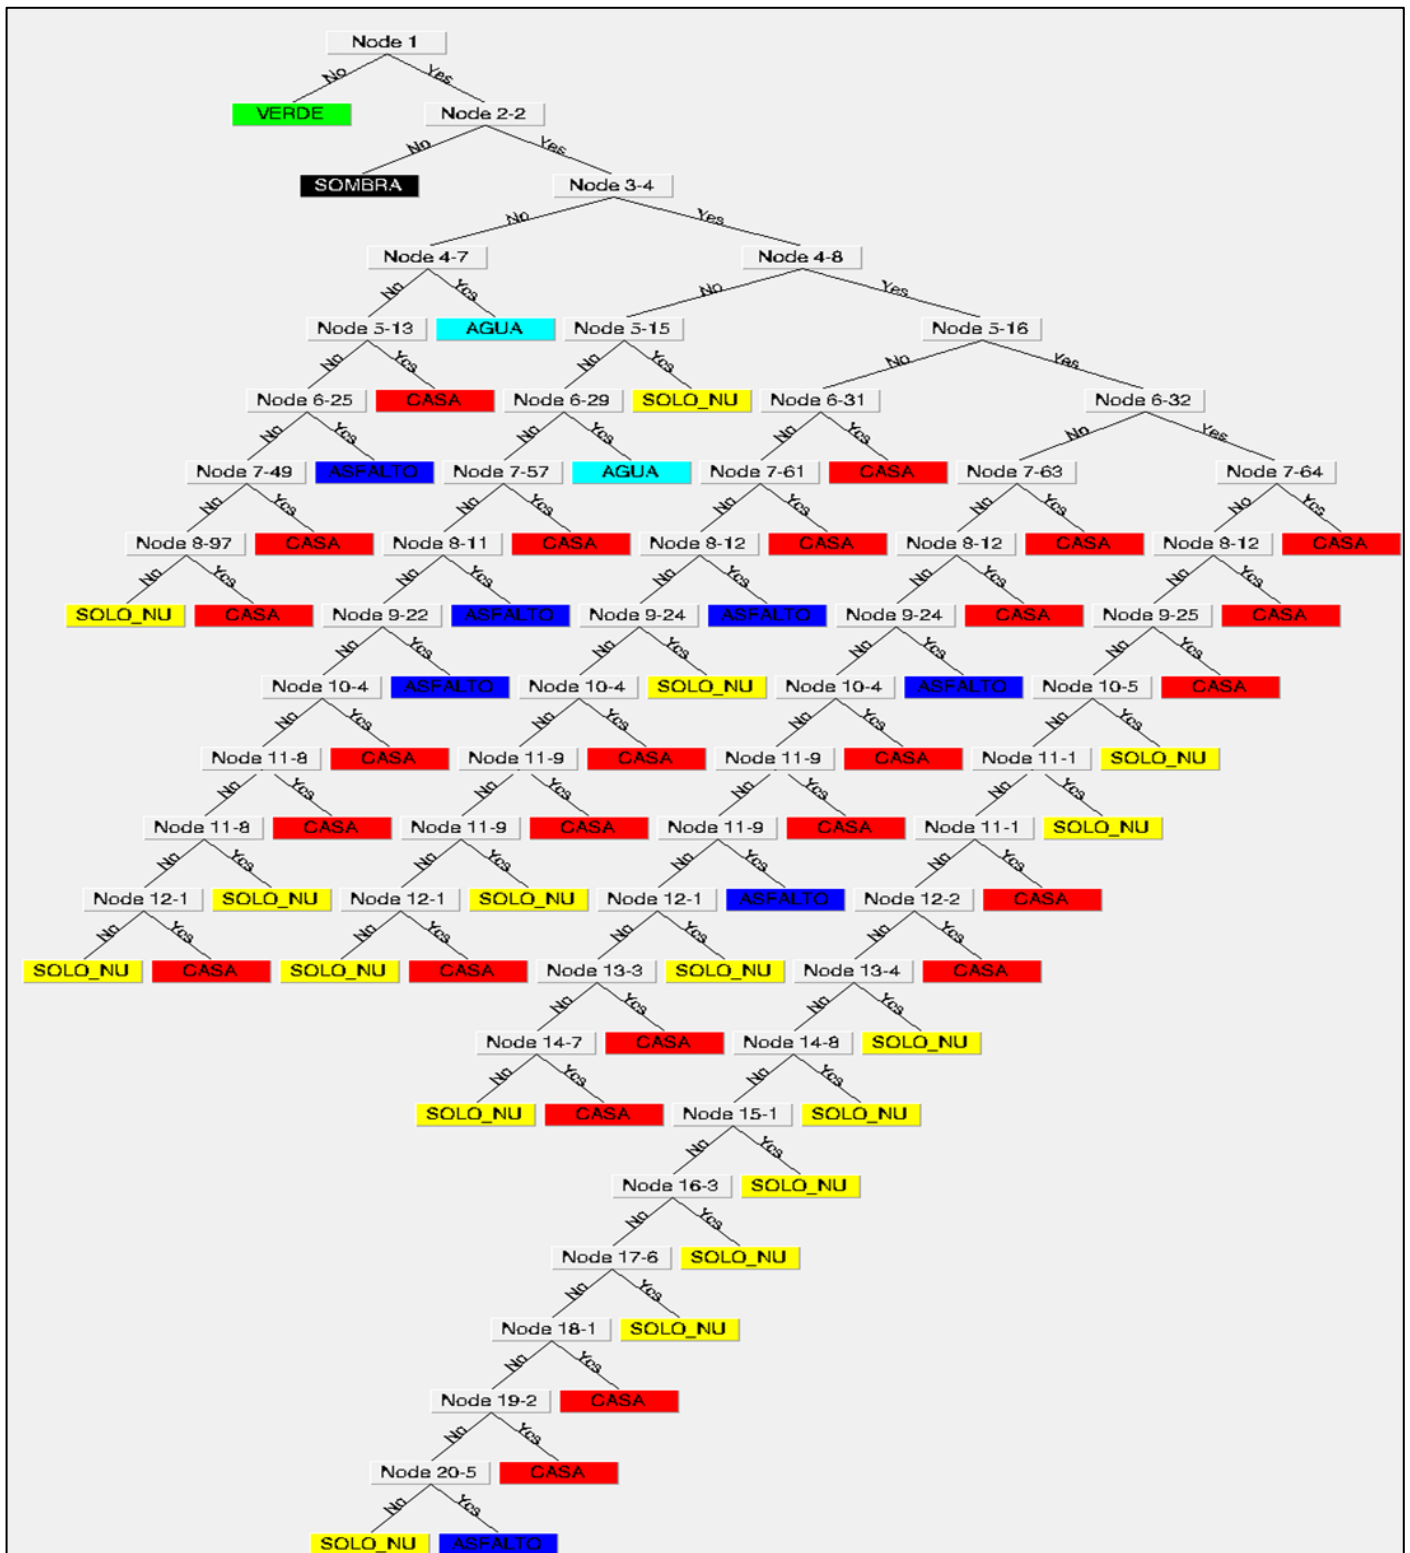
<https://www.analyticsvidhya.com/blog/2017/09/understaing-support-vector-machine-example-code/> (Consultado em 26/09/47JUN2019)

<http://svm.michalhaltuf.cz/support-vector-machines/>, (Consultado em 15JUN2019)

<https://rpubs.com/hudsonchavs/maxverosimilhanca>, (Consultado em 06JUN2019)


https://ciencias.ulisboa.pt/sites/default/files/fcul/unidservico/bib/APA_FCULv2.pdf (consultado em 23AGO2019)

ANEXO A – ÁRVORE DE DECISÃO DA ORTOIMAGEM




ANEXO B – AMOSTRA DE HISTOGRAMAS DA ORTOIMAGEM


- Determinação do *threshold* para a classe sombra através da banda 2 da imagem




- Determinação do *threshold* para a classe água através do índice NDVI da imagem



- Determinação do *threshold* para a classe solo nu através do índice NDVI da imagem



- Determinação do *threshold* para a classe casa através do índice RRR da imagem



- Determinação do *threshold* para a classe asfalto através do índice RRR da imagem

